

**SVEUČILIŠTE U ZAGREBU**  
**FAKULTET PROMETNIH ZNANOSTI**

**Josip Lučić**

**PRIMJENA BESPILOTNIH LETJELICA ZA ANALIZU PROMETA U  
GRADOVIMA**

**DIPLOMSKI RAD**

Zagreb, rujan 2017.

Zagreb, 24. travnja 2017.

Zavod: **Zavod za inteligentne transportne sustave**  
Predmet: **Inteligentni transportni sustavi I**

## DIPLOMSKI ZADATAK br. 4275

Pristupnik: **Josip Lučić (0035184180)**  
Studij: **Inteligentni transportni sustavi i logistika**  
Smjer: **Inteligentni transportni sustavi**


Zadatak: **Primjena bespilotnih letjelica za analizu prometa u gradovima**

### Opis zadatka:

U diplomskom radu potrebno je analizirati koncept i primjenu bespilotnih letjelica za analizu prometa u gradovima. U radu je potrebno provesti analizu zakona i regulative za uporabu bespilotnih letjelica u naseljenim područjima. Također, potrebno je istražiti i opisati metodološke postupke za snimanje prometa u urbanim područjima te provesti usporednu analizu programskih alata i manualnih postupaka za ekstrakciju prometnih veličina iz video zapisa bespilotnih letjelica.

Zadatak uručen pristupniku: 28. travnja 2017.

Mentor:

---

dr. sc. Pero Škorput

Predsjednik povjerenstva za  
diplomski ispit:

---

SVEUČILIŠTE U ZAGREBU  
FAKULTET PROMETNIH ZNANOSTI

## **DIPLOMSKI RAD**

**PRIMJENA BESPILOTNIH LETJELICA ZA ANALIZU PROMETA U  
GRADOVIMA**

**Application of Unmanned Aerial Vehicles for Traffic Analysis in  
Cities**

Mentor: dr. sc. Pero Škorput  
Student: Josip Lučić, 0035184180

Zagreb, rujan 2017.

## SAŽETAK

Primjenom inovativnih rješenja kao što su bespilotne letjelice moguće je lakše i uz značajno manje financijske izdatke analizirati prometne parametre određenog područja. Klasične tehnologije koje se upotrebljavaju u analizama prometa u gradovima najčešće uključuju manualno brojanje prometa u zonama od interesa odnosno analize iz različitih brojača prometa. Usporedit će se metodološki postupci i softwareski alati za ekstrakciju prometnih veličina iz videozapisa bespilotnih letjelica te će se provesti verifikacija procijenjenih veličina prometnog toka dobivenih iz videozapisa u odnosu na manualno dobivene podatke. U ovom diplomskom radu tema je obrađena kroz opis koncepta i primjene bespilotnih letjelica u različitim područjima što za sobom povlači analizu zakona i regulativa vezanih uz njih. Istražene su postojeće metodologije korištenja bespilotnih letjelica za snimanje prometa u gradovima. Pred kraj rada dana je usporedna analiza softwareskih alata i manualnih postupaka za ekstrakciju prometnih veličina iz videozapisa bespilotnih letjelica.

Ključne riječi: bespilotne letjelice; analiza prometa; gradovi

## SUMMARY

Application of innovative solutions like unmanned aerial vehicles makes it possible for easier analysis of traffic parameters in defined areas with significantly less financial costs. Classic technologies that are used in traffic analysis in cities usually involve manual counting of traffic in zones of interest with reference to analysis from different traffic counting mechanisms. There will be comparison of methodological processes and software tools for extraction of traffic parameters out of videos obtained from unmanned aerial vehicles as well as verification of estimated traffic parameters from video in relation to manually given data. In this final work, the topic will be processed through description of concept and application of unmanned aerial vehicles in different areas which requires analysis of laws and regulations related to them. Existing methodology of unmanned aerial vehicle usage for recording traffic in cities is explored. Comparative analysis of software tools and manual method for extracting traffic parameters from unmanned aerial vehicles recordings has been given towards the end of this final work.

Keywords: unmanned aerial vehicles; traffic analysis; cities

# Sadržaj

1.	Uvod .....	1
2.	Karakteristike primjena bespilotnih letjelica.....	3
2.1.	Koncept operacija.....	5
2.1.1.	Slobodna kategorija.....	7
2.1.2.	Specifična kategorija.....	7
2.1.3.	Ovlaštena kategorija.....	8
2.2.	Primjena bespilotnih letjelica .....	8
2.2.1.	Primjena bespilotnih letjelica u policijske svrhe .....	9
2.2.2.	Primjena bespilotnih letjelica u upravljanju katastrofama i velikim nesrećama.....	11
2.2.3.	Primjena bespilotnih letjelica za dostavu paketa .....	12
2.2.4.	Primjena bespilotnih letjelica za analizu prometa .....	13
3.	Zakoni i regulative korištenja bespilotnih letjelica u naseljenim područjima .....	15
3.1.	Pravilnik o sustavima bespilotnih zrakoplova .....	15
3.1.1.	Opće odredbe .....	16
3.1.2.	Pravila letenja .....	17
3.2.	Uredba o snimanju iz zraka .....	20
3.3.	Pregled zakonske regulative u europskim državama .....	22
4.	Metodologija korištenja bespilotnih letjelica za snimanje prometa u gradovima.....	24
4.1.	Definicija opsega djelovanja studije .....	25
4.2.	Planiranje leta za prikupljanje podataka pomoću bespilotne letjelice .....	26
4.3.	Izvedba leta bespilotnom letjelicom .....	28
4.4.	Prikupljanje podataka pomoću videosnimke sa bespilotne letjelice .....	29
4.5.	Analiza i obrada podataka dobivenih sa videosnimke bespilotne letjelice.....	30
4.5.1.	Poluautomatska video analiza.....	31
4.5.2.	Automatska video analiza .....	31
4.6.	Tumačenje dobivenih podataka .....	31
4.7.	Apliciranje dobivenih rezultata za optimiziranje prometa.....	32
5.	Usporedna analiza softwareskih alata i manualnih postupaka za ekstrakciju prometnih veličina iz videozapisa bespilotnih letjelica.....	33
5.1.	Softwareski alati za ekstrakciju prometnih veličina iz videozapisa .....	34
5.1.1.	Picomixer STA .....	37
5.1.2.	DataFromSky .....	39

5.2.	Manualna ekstrakcija prometnih veličina iz videozapisa .....	42
6.	Mjerenje razine usluge i procjena PGDP-a na području užeg središta Sesveta (Zagrebačka cesta) 44	
6.1.	Metoda 1. Gustoća i protok iz fiksnih kadrova .....	45
6.2.	Metoda 2. Gustoća i protok iz serijskih okvira .....	47
6.3.	Procjena PGDP-a.....	48
7.	Zaključak .....	50
8.	Literatura .....	51
9.	Popis kratica .....	54
10.	Popis tablica.....	55
11.	Popis slika .....	56

## 1. Uvod

Primjenom inovativnih rješenja kao što su bespilotne letjelice moguće je lakše i uz značajno manje financijske izdatke analizirati prometne parametre određenog područja. Klasične tehnologije koje se upotrebljavaju u analizama prometa u gradovima najčešće uključuju manualno brojanje prometa u zonama od interesa odnosno analize iz različitih brojača prometa. U ovom diplomskom radu analizirani su koncept i primjena bespilotnih letjelica te zakonske regulative korištenja bespilotnih letjelica u naseljenim područjima. Opisani su metodološki postupci i softwareski alati za ekstrakciju prometnih veličina iz videozapisa bespilotnih letjelica. Također provedena je verifikacija procijenjenih veličina prometnog toka dobivenih iz videozapisa u odnosu na manualno dobivene podatke.

Svrha ovog diplomskog rada je identificirati i opisati tehničko tehnološka rješenja primjene bespilotnih letjelica u funkciji mjerenja prometnih veličina na prometnim tokovima u urbanim sredinama. Cilj istraživanja je da se analizom videosnimaka utvrde i verificiraju metodološki postupci za provedbu prometnih analiza.

Dosadašnja istraživanja uglavnom se odnose na analize tehničkih rješenja i funkcionalnosti pojedinačne primjene bespilotnih letjelica kao što su performanse leta, autonomija bespilotnih letjelica, komunikacijske tehnologije s bespilotnim letjelicama i slično. Svega nekolicina radova ozbiljnije razmatra mogućnosti primjene bespilotnih letjelica u funkciji analize prometnih tokova u urbanim sredinama.

Očekivani rezultat ovog istraživanja leži u identifikaciji, validaciji i verifikaciji metodoloških postupaka mjerenja prometnih veličina primjenom bespilotnih letjelica u urbanim sredinama.

U drugom poglavlju je analiziran koncept i primjena bespilotnih letjelica. Opisane su karakteristike i vrste bespilotnih letjelica. Zatim je dan i objašnjen primjer koncepta i primjene bespilotnih letjelica u zračnom prostoru kroz tri kategorije: slobodna, specifična i ovlaštena. Opisana je njihova primjena kroz razna područja u kojima se primjenjuju te je zasebno objašnjena i ona koja se odnosi na analizu prometa u gradovima.



Treće poglavlje se odnosi na trenutnu zakonodavnu situaciju sa bespilotnim letjelicama. U Republici Hrvatskoj postoje dva dokumenta koja se odnose na korištenje bespilotnih letjelica u naseljenom području. Detaljno je analiziran pravilnik o sustavima bespilotnih zrakoplova kao i uredba o snimanju iz zraka. Cilj ovih dokumenta je omogućiti sigurno korištenje bespilotnih letjelica uz sačuvanje privatnosti, okoline i ostalih sudionika zračnog prostora. Na kraju poglavlja dan je kratak pregled zakonskih regulativa vezanih uz bespilotne letjelice u ostalim europskim državama.

Četvrto poglavlje obuhvaća i utvrđuje niz postupaka potrebnih kako bi se moglo kvalitetno provesti snimanje prometa u gradovima. Kao neka baza uzet će se sedam osnovnih koraka potrebnih za snimanje prometa u gradu: definicija opsega djelovanja, planiranje leta, izvedba leta, prikupljanje podataka, analiza i obrada podataka, tumačenje podataka, apliciranje dobivenih rezultata za optimiziranje prometa. Kroz ovih sedam koraka bit će objašnjeni svi postupci koji su potrebni da bi se obavilo snimanje iz zraka. Od osnovnih stvari kao što je određivanje područja snimanja, odabir tipa letjelice, planiranje rute letenja pa sve do kompleksnijih koji uključuju analizu i obradu prikupljenih podataka pomoću raznih algoritama.

U petom poglavlju će se provesti analiza postojećih softwareskih alata za analizu videozapisa sa bespilotne letjelice. Opisan je postupak analize videozapisa kroz više koraka te način ekstrakcije prometnih veličina sa tog videozapisa. Cijeli ovaj postupak analiziran je i sa pogleda točnosti koju daje u odnosu na manualnu ekstrakciju ili manualno prikupljanje podataka. Kao primjer dana su dva softwareska alata Picomixer STA i DataFromSky sa opisom njihovih mogućnosti. Provest će se također i analiza manualnih postupaka za ekstrakciju prometnih veličina iz videozapisa te će se na kraju dobiveni rezultati usporediti.

## 2. Karakteristike primjena bespilotnih letjelica

Bespilotne letjelice se već neko vrijeme razmatraju za primjenu u raznim područjima kao što je nadziranje objekata, nadziranje prometa, usluge dostave paketa, operacije potrage i spašavanja, fotografiranje i mnogim drugima. Prethodno su bespilotne letjelice korištene samo u vojne svrhe za izviđačke misije i kasnije za kontroverzni program američke vojske koji je koristio bespilotne letjelice za napadanje određenih strateških ciljeva [1]. Uvođenje manjih bespilotnih letjelica u civilne svrhe uzrokovalo je popriličnu strku za zakonodavce i regulatorna tijela iz razloga što do onda praktički nisu postojali zakoni vezani uz njihovu primjenu.

Potrebno je bespilotne letjelice integrirati u postojeći zračni sustav na siguran način pa da ta integracija potakne europsku industriju za njih na razvitak. Samim time došlo bi do otvaranja novih radnih mjesta i omogućilo bi daljnji rast industrije. Razmatrajući velik broj primjena i tipova bespilotnih letjelica predložile bi se tri kategorije operacija i njihovi regulatorni režimi: slobodna, specifična i ovlaštena. Bespilotne letjelice možemo svrstati u slijedeće kategorije:

*Micro* bespilotne letjelice naziv su dobile zbog svoje veličine koja im omogućuje da budu transportirane unutar ruksaka ili kovčega. Letjelice se koriste na malim visinama (do 300 m), s ograničenim trajanjem baterije što za posljedicu ima kratko vrijeme leta koje može iznositi maksimalno do 30 minuta.

*Vertical take-off and landing* ili skraćeno VTOL letjelice imaju mogućnost vertikalnog polijetanja i slijetanja te su odličan izbor za primjenu u područjima sa terenskim ograničenjima. Letjelice uglavnom operiraju na malim visinama i također imaju ograničeno vrijeme leta.

*Low altitude short endurance* bespilotne letjelice (slika 1) na zahtijevaju postojanje uzletno-sletne staze već se mogu pokrenuti ručno ili sa minijaturnih katapulta. Komponente letjelice obično ne premašuju 5 kg i imaju raspon krila manji od 3 m. Mogu izvršavati operaciju u trajanju od 1 do 2 sata i unutar nekoliko kilometara od zemaljske postaje.




Slika 1. Low altitude short i long endurance sustavi [36]

*Low altitude long endurance* sustavi bespilotnih letjelica mogu nositi teret težak nekoliko kilograma na visinama od nekoliko tisuća metara dulje vremensko razdoblje što može biti i preko 24 sata.

*Medium altitude long endurance* bespilotne letjelice su znatno veće od letjelica koje lete na nižim visinama. Operiraju na visinama do 9 tisuća metara na letovima udaljenim stotinama kilometara od njihovih zemaljskih postaja, u trajanju od više sati.

High altitude long endurance kategorija predstavlja najveće i najsloženije sustave bespilotnih letjelica. Ove letjelice mogu letjeti na visinama većim i do 20.000 metara i udaljenostima koje premašuju tisuću kilometara od zemaljske postaje. Neke imaju trajanje leta veće od 30 sati te su postavile rekorde u visini i trajanju leta.



Slika 2. Prikaz bespilotne letjelice prilikom nadzora prometa [16]

Da bi se olakšala gore navedena podjela, bespilotne letjelice možemo grupirati tako da dobijemo slijedeću podjelu [2]:

1. Mini
2. Short range
3. Medium range
4. High altitude long endurance.

Na slici 2 je prikazan primjer upotrebe bespilotne letjelice, a kako bi se provodile operacije bespilotnim letjelicama potrebno je odrediti sigurnosni rizik koji operacije predstavljaju za okolinu. U njemu je potrebno osigurati zaštitu određenih javnih interesa od kojih se uz sigurnost ističe i područje naše privatnosti.


## **2.1. Koncept operacija**

Operacije bespilotnih letjelica bi se trebale kategorizirati s obzirom na njihovu kompleksnost i rizik koji predstavljaju. Što je veća kompleksnost i rizik to je veći broj potrebnih dozvola i ovlaštenja koje je potrebno ishoditi prije provođenja letačkih

operacija. Uzevši u obzir široko područje primjena i tipova bespilotnih letjelica, predložene su tri kategorije: slobodna, specifična i ovlaštena.

Slobodna kategorija ne bi zahtijevala ovlaštenja od strane nadležne agencije za civilno zrakoplovstvo ali bi bespilotna letjelica morala ostati unutar određenih ograničenja (npr. udaljenost od zračnih luka, ljudi i dr.). Specifična kategorija će zahtijevati dopuštenje za izvođenje letačke operacije od agencije za civilno zrakoplovstvo u kojemu će biti i navedena posebna ograničenja za tu operaciju ukoliko agencija smatra da su potrebna. Za treću kategoriju biti će potrebno proći isti proces i ishoditi iste dozvole kao da se radi o letjelici sa pilotom u zračnom prostoru. Ovakav koncept je razvijen kako bi adresirao dva glavna cilja:

- Integracija i prihvaćanje bespilotnih letjelica u postojeći zračni sustav na siguran način (prijedlog amazona na slici 3)
- Poticanje inovativne i kompetitivne europske industrije za bespilotne letjelice.



Slika 3. Prijedlog dizajna zračnog prostora za male dronove od amazona [1]

Kako bi se ostvarila oba cilja istovremeno, regulatorna tijela trebaju postaviti određenu razinu sigurnosti, zaštite okoliša i javnih interesa koja je prihvatljiva društvu ali i omogućiti dovoljno fleksibilnosti za novu industriju kako bi se razvila. Sigurnosni rizici koji se trebaju uzeti u obzir su:

- Sudar u zraku sa zrakoplovom kojim upravlja osoba,
- Opasnost za ljude,
- Šteta na imovini.

#### **2.1.1. Slobodna kategorija**

Slobodna kategorija se odnosi na operacije s bespilotnim letjelicama niskoga rizika. Nisu potrebne nikakve dozvole ili licence za operatere i pilote jer u ovu kategoriju nije uključena agencija za civilno zrakoplovstvo. Kategorija je osmišljena kako bi dozvolila jednostavne operacije bez dodatnih troškova za dobivanje dozvola i time omogućila malim i srednjim poduzećima da prikupe iskustvo. Rizik za ostale korisnike se umanjuje kroz odvajanje zračnog prostora bespilotnih letjelica od zračnog prostora letjelica sa pilotima. Kako bi se to postiglo bespilotna letjelica mora letjeti:

- Unutar vidokruga od 500m
- Na visini koja ne prelazi 150m iznad zemlje ili vode
- Izvan specifičnih zatvorenih zona (zračne luke).

Rizik za ljude se smanjuje kroz uporabu bespilotnih letjelica male energije i utvrđivanjem minimalnih udaljenosti u odnosu na ljude na zemlji. Letovi iznad gomila su zabranjeni, ali letovi iznad ljudi koji se ne nalaze u gradu ili naseljenom području su dozvoljeni. Bespilotne letjelice su danas dostupne na tržištu sa mnogim sigurnosnim mogućnostima kao što je padobran ili pomoć operateru bespilotne letjelice da poštuje maksimalnu visinu i/ili ostane izvan određenih zabranjenih zona za let.

#### **2.1.2. Specifična kategorija**

Specifična kategorija se odnosi na operacije koje ne zadovoljavaju uvjete slobodne kategorije. Operater treba provesti procjenu sigurnosnog rizika na način da identificira i predloži mjere koje će smanjiti rizik letačke operacije. Nakon što ih je odredio predaje ih agenciji za civilno zrakoplovstvo koje ih pregledava i ukoliko ih prihvati odobrava. U procjeni sigurnosnog rizika treba analizirati sposobnost letjelice za siguran let,

operativne procedure, utjecaj na okoliš, sposobnost uključenog osoblja i probleme zračnog prostora.

### **2.1.3. Ovlaštena kategorija**

Posljednja kategorija mogla bi se usporediti sa procedurom koju prolazi zrakoplov sa pilotom prije leta. Letjelica mora proći razna testiranja kao bi se utvrdila njezina sigurnost, mora u sebi sadržavati sustav za izbjegavanje sudara u zraku. Održavanje letjelice se treba provoditi redovito i od strane kvalificiranog osoblja za taj posao. Operater i osoblje moraju biti licencirani za upravljanje bespilotnom letjelicom. Bespilotna letjelica se mora pridržavati unaprijed određenog plana leta i operater mora cijelo vrijeme biti u kontaktu sa kontrolom zračnog prometa.

Ključna područja istraživanja za integraciju u ne odvojeni zračni prostor su [3]:

- Sustav detektiraj i izbjegni
- Pristup zračnom prostoru i zračnim lukama
- Komunikacija između letjelice i operatera
- Ljudski faktor
- Sigurnost
- Autonomnost

## **2.2. Primjena bespilotnih letjelica**

Pogledamo li razvoj bespilotnih letjelica unatrag 15-ak godina, vidimo da je postignut velik napredak na tom području. Širina primjene bespilotnih letjelica je velika. Dostupnost tehnologije na tržištu je omogućila da se strogo vojne letjelice prenamijene u civilne svrhe gdje postoji veliki potencijal za njihovu primjenu. Razvoj računalne, senzorske i komunikacijske tehnologije kao i razvoj lakih materijala uzrokovali su povećani interes za primjenom bespilotnih letjelica u različite svrhe.

Kombinacijom bespilotnih letjelica sa ITS-om moguće je novim inovativnim metodama još više unaprijediti sigurnost, učinkovitost i zaštitu okoliša u prometu.

Danas bespilotne letjelice možemo koristiti u razne vojne i civilne svrhe. Od izviđanja i špijuniranja pa sve do nadzora granica, mora i primjena u policijske, protupožarne ili neke druge svrhe.

### **2.2.1. Primjena bespilotnih letjelica u policijske svrhe**

U današnje vrijeme je diljem svijeta rasprostranjena primjena bespilotnih letjelica u policijske svrhe. Koriste se od nadgledanja granica, kontrole zabrane ribolova pa sve do akcija protiv krijumčarenja droge i oružja. Svakim danom otkrivanjem novih mogućnosti za primjenu, bespilotne letjelice nameću se kao sustavi budućnosti.

Za policijsku namjenu mogu se navesti dva koncepta bespilotnih letjelica. Jedan koncept bi bio upravljiv iz policijskog centra, opremljen sa visoko razlučivim kamerama i mikrofonima visoke osjetljivosti koji bi uglavnom služio za nadzor i praćenje (slika 4). Drugi koncept bi se bazirao na minijaturnim bespilotnim letjelicama koje bi se vozile unutar službenog vozila i bile korištene prema potrebi osoblja na terenu.



**Slika 4.** Video nadzor bespilotnom letjelicom [17]

Prvi tip potrebne bespilotne letjelice je već duže vrijeme dostupan na tržištu i uz male preinake se može vrlo jednostavno prilagoditi potrebama policije. Ti sustavi su i



u načelu dizajnirani i korišteni za nadgledanje, slikanje i određivanje mogućih ciljeva unutar vojnih snaga.

Drugi tip bespilotnih letjelica dolazi sa manjim komplikacijama. Minijaturne bespilotne letjelice su za sada još uvijek slabo razvijene i unatoč činjenici da je današnja tehnologija „vrlo sitna“ još uvijek je prevelika za takve letjelice. Problem predstavlja također i korisna težina bespilotne letjelice [4].



**Slika 5.** Britanski policijski dron [18]


Na slici 5 vidimo primjer policijskog drona i kada se govori o upotrebi bespilotnih sustava u policiji, nameće se pitanje kako će se spriječiti sudar bespilotne letjelice u zgradu ili u žicu dalekovoda. U urbanim sredinama nema puno prostora za manevriranje te je potrebna tip bespilotne letjelice koji može funkcionirati u takvim uvjetima. Sustav bi se temeljio na principu helikoptera koji je za tu zadaću mnogo bolje rješenje od klasičnog sustava zrakoplova. Lansiranje i prihvat letjelice je jednostavno jer ne zahtijeva rampe za lansiranje, te površine za zalet i uzlijetanje. VTOL tehnologijom je omogućeno da u slučaju otkazivanja motora letjelica može autorotacijom sigurno sletjeti na tlo, vrh zgrade ili vozilo.

### 2.2.2. Primjena bespilotnih letjelica u upravljanju katastrofama i velikim nesrećama

Paralelno s češćom pojavom velikih nesreća i katastrofa raste i značaj upravljanja te uklanjanja njihovih posljedica. Jedna od metoda unapređivanja je korištenje bespilotnih letjelica.

Najveći problemi kod upravljanja katastrofama i nesrećama javljaju se kod procjene situacije. U odgovoru na katastrofe operateri, odnosno zapovjednici, moraju djelovati tako da učinkovito koordiniraju osoblje i resurse. Kako bi se to učinilo brzo i efikasno potrebne su informacije s mjesta katastrofe. Te informacije često stižu kasno i nisu točne. To dovodi do sporog i neučinkovitog odgovora, a samim time i katastrofalnih posljedica. Dakle, dolazimo do zaključka da dostupnost stvarnovremenskih informacija u slučaju katastrofa i velikih nesreća ima ključnu ulogu za brz i učinkovit odgovor.

Duga izdržljivost, male dimenzije, brzo kretanje prostorom, velika slika površine koju nadgledaju (slika 6), letenje u gotovo svim uvjetima i nepostojanje opasnosti od ljudskih žrtava ključne su prednosti koje bespilotne letjelice pružaju. Sa nabrojenim prednostima bespilotne letjelice bi mogle imati veliku ulogu u upravljanju katastrofama i velikim nesrećama.



Slika 6. Pregled područja pogođenog katastrofom [19]

Letjelicama bi upravljali operateri Državne uprave za zaštitu i spašavanje, a mogle bi se iskoristiti za:

- detekciju mjesta katastrofe ili velike nesreće
- lociranje mjesta katastrofe ili velike nesreće
- pružanje stvarnovremenskih informacija
- traganje za unesrećenima
- isporuci prve pomoći unesrećenima
- praćenje razvoja situacije
- uspostavu komunikacije
- procjenu štete i očevid.

Kroz gore navedene mogućnosti primjene bespilotne letjelice u ove svrhe vidimo koliki bi značaj mogle imati u ovim situacijama. Primjenjive su u gotovo svakoj fazi upravljanja katastrofama. Ključne su u prvim fazama gdje se pomoću njih može verificirati mjesto katastrofe i dobit osnovne informacije poput lokacije, vrste nesreće i same težine nesreće. Pružaju pogled iz zraka što ih čini jednim od načina za traganjem za unesrećenima ili načinom za procjenu štete i očevid.

### **2.2.3. Primjena bespilotnih letjelica za dostavu paketa**

Parcelokopteri bazirani na GPS navigaciji već danas dostavljaju hitne medicinske i ostale potrepštine na teško dostupna područja. Planovi za slanje parcelokoptera u svakodnevne dostave su još uvijek u ranoj fazi ali su tehnološki mogući danas. Neke tvrtke, kao što je Amazon, već su započele sa dostavom paketa putem bespilotnih letjelica dok druge to tek planiraju uvesti.



Slika 7. Беспилотна летјеліца за доставу пакета [20]

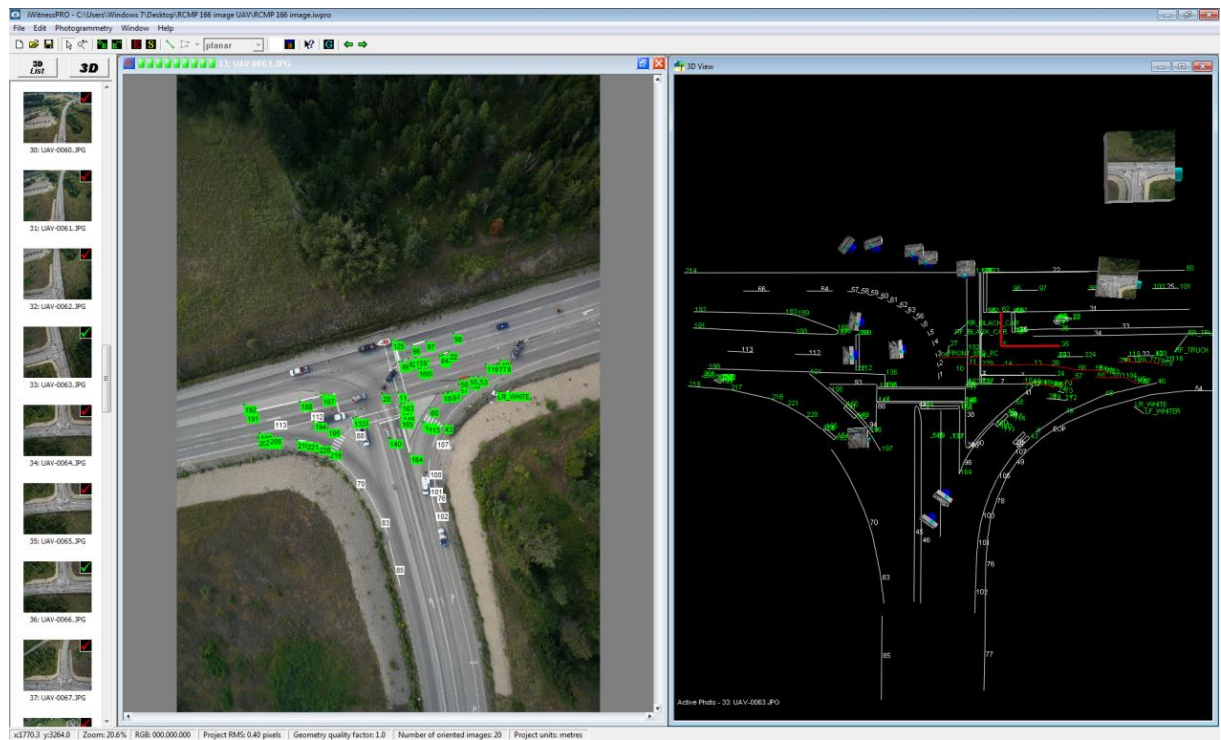
Bespilotna letjelica za dostavu paketa sa slike 7 već se koristi u te svrhe. Letjelica teži 2.6 kg i može ostati u zraku do 90 minuta i postići maksimalnu brzinu od 50 km/h [5].

#### 2.2.4. Primjena bespilotnih letjelica za analizu prometa

Porastom prometa na hrvatskim cestama rastu i zagušenja, što rezultira povećanjem broja incidentnih situacija, povećanjem onečišćenja, povećanjem štetnih emisija i potrošnje goriva, povećanjem troškova putovanja, itd. Postojeća cestovna mreža ne može u potpunosti zadovoljiti prometnu potražnju u vršnim satima. Zbog toga bi bespilotne letjelice bi u kombinaciji s ITS-om bile kvalitetno rješenje.

Da bi se stanje u cestovnom prometu dovelo na zadovoljavajuću razinu potrebno je znati stvarnovremenske podatke sa prometne mreže. Točne i kvalitetne podatke o stanju na prometnoj mreži gotovo je nemoguće dobiti sa zemlje, odnosno uz pomoć konvencionalnih metoda, stoga je neophodno kontinuirano nadziranje iz zraka.

Korištenjem bespilotnih letjelica za nadzor i upravljanje prometom ostvarila bi se znatna poboljšanja kod pružanja preciznih i stvarnovremenskih podataka o stanju na prometnoj mreži. Uz pomoć dobivenih podataka (slika 8) omogućila bi se bolja kontrola i upravljanje prometom.



**Slika 8.** Korištenje snimke za analizu prometnih tokova na raskrižju [21]

Tako bi se u Republici Hrvatskoj u sklopu centara za održavanje i kontrolu prometa bespilotne letjelice mogle primjenjivati za:

- nadgledanje stanja na cestama
- pružanje putnih i predputnih informacija
- nadzor kršenja prometne regulative
- prikupljanje podataka koji se odnose na upotrebu i zloupotrebu cestovnih mreža
- nadzor brzine kretanja
- detekcija vožnje u krivom smjeru
- detekciju područja zagušenja
- pružanje podrške interventnim službama
- nadzor vremenskih uvjeta i okoliša.

Prednost bespilotnih letjelica u odnosu na nadzor prometa sa helikopterom ili zrakoplovom je u njihovim električnim motorima što pruža gotovo nečujno nadziranje prometa bez ometanja i uznemiravanja sudionika [6].

### **3. Zakoni i regulative korištenja bespilotnih letjelica u naseljenim područjima**

Širenjem civilne upotrebe bespilotnih letjelica uvidjele su se mnoge opasnosti koje bi se mogle pojaviti te se pojavila potreba za donošenjem zakona i regulativa. Zabilježene su nezakonite uporabe bespilotnih letjelica diljem svijeta kojima su ugrožavani ljudski životi i koji nisu u skladu s određenim zakonima poput zakona o zaštiti osobnih podataka. Kako bi se ograničila i regulirala upotreba bespilotnih letjelica mnoge države su donijele posebne zakone o toj temi ili su zakoni u izradi.

Zakoni su doneseni prvenstveno zbog sigurnosti ljudi čiji bi život mogao biti ugrožen uporabom bespilotnih letjelica. Pojavljuje se i problem zaštite osobnih podataka s kojim bi svaki rukovatelj bespilotnim zrakoplovom trebao biti upoznat. Također je određenim zakonima potrebno urediti kvalitetu podataka koja bi bila iskoristiva u određene svrhe.

Prije nego se krene u analizu zakona i regulativa za korištenje bespilotnih letjelica potrebno je spomenuti kako su u Hrvatskoj bitna dva pravna akta koja se odnose na to područje, a to su: Pravilnik o sustavima bespilotnih zrakoplova i Uredba o snimanju iz zraka. Kroz ovo poglavlje bit će objašnjena pravila oba akta.

#### **3.1. Pravilnik o sustavima bespilotnih zrakoplova**

Sve većim korištenjem bespilotnih letjelica u civilne svrhe pojavila se potreba za pravilnikom koji će odrediti pravila prema kojima će se letjelice smjeti koristiti u naseljenim područjima. Pravilnik dolazi sa određenim područjem primjene te se primjenjuje na bespilotne letjelice operativne mase do 150 kilograma i uključujući 150 kilograma, bespilotne letjelice koje se koriste na otvorenom prostoru a ne u zatvorenom i samo na bespilotne letjelice koje mogu postići kinetičku energiju veću od 79 J. Ovaj pravilnik se odnosi samo na uporabu bespilotnih letjelica u civilne svrhe, ne kada se koriste u državne aktivnosti (vojne, policijske, sigurnosno-obavještajne, carinske, potrage i spašavanja, gašenje požara i dr.).



### 3.1.1. Opće odredbe

Prvi dio pravilnika se odnosi na opće odredbe i odmah klasificira bespilotne letjelice prema njihovoj operativnoj masi (ukupna masa bespilotnog zrakoplova u trenutku polijetanja) te se dijele na klase koje su određene masom letjelice. Klasa 5 se odnosi na sve bespilotne letjelice čija masa ne premašuje 5 kilograma. Bespilotne letjelice koje se koriste kod ovakvog tipa istraživanja spadat će u ovu klasu i odredbe koje se odnose na ovu klasu vrijediti će za njih. Osim klase 5 tu su i klase 25 i 150 koje se odnose na bespilotne letjelice između 5 i 25 kilograma, odnosno između 25 i 150 kilograma.

Slijedeća klasifikacija je klasifikacija područja letenja. U ovom slučaju klase se određuju na temelju izgrađenosti, naseljenosti i prisutnosti ljudi te se područja letenja dijele se na klase od I do IV. Klase su podijeljene tako da klasa I predstavlja područje gdje postoji najmanji rizik prilikom letenja s bespilotnom letjelicom, a klasa IV predstavlja područje s najvećim rizikom prilikom izvođenja letačkih operacija.

Prva klasa obuhvaća područje u kojemu nema izdignutih građevina ili objekata i u kojemu nema ljudi. Pod drugu klasu spade područje u kojemu se također ne nalaze ljudi ali u njemu postoje neki pomoćni gospodarski objekti ili građevine koje nisu namijenjene za boravak ljudi. U treću klasu spadat će područje u kojemu se nalaze građevine ili objekti primarno namijenjeni za stanovanje, poslovanje ili rekreaciju (stambene zgrade, stambene kuće, škole, uredi, sportski tereni, parkovi i slično). I u posljednju, najriskantniju klasu spada područje tzv. uskih urbanih zona kao što su središta gradova, naselja i mjesta.

**Tablica 1.** Kategorizacija letačkih operacija

Klasa sustava bespilotnog zrakoplova	Klasa područja izvođenja letenja			
	I	II	III	IV
<b>5</b> OM < 5 kg	A	A	B	C
<b>25</b> 5 ≤ OM ≤ 25 kg	A	B	C	D
<b>150</b> 25 ≤ OM ≤ 150kg	B	C	D	D

Izvor: [22]

Nakon toga u pravilniku se vrši kategorizacija letačkih operacija koje se određuju razinom rizika koji njihovo izvođenje predstavlja za okolinu i dijeli se u četiri skupine A, B, C, D. Prikaz kategorizacije letačkih operacija možemo vidjeti u tablici 1.

Kao što vidimo kategorija A predstavlja operaciju s minimalnom opasnosti, dok kategorija D predstavlja operaciju s maksimalnom. Oznaka OM u tablici predstavlja operativnu masu letjelice.

Letenje bespilotnim zrakoplovnim modelom dozvoljeno je u područjima letenja klase I i II. Također se propisuje obavezno osiguranje, operator mora ishoditi policu osiguranja u skladu s propisom kojim se uređuju obavezna osiguranja u prometu. Operator mora ishoditi i odobrenje za korištenje radio frekvencijskog spektra u skladu s posebnim propisom kada je to primjenjivo.

Jedan od članaka, točnije članak 9, se odnosi na označavanje bespilotnog zrakoplova. U članku je određeno da bespilotni zrakoplov operativne mase veće od 5 kg koji se koristi za izvođenje letačkih operacija mora biti označen identifikacijskom negorivom pločicom. Označavanje bespilotnog zrakoplova mora izvršiti operator te identifikacijska negoriva pločica mora biti odgovarajuće veličine kako bi omogućila jasnu identifikaciju i mora biti pričvršćena postojanim načinom.

### **3.1.2. Pravila letenja**

Prilikom izvođenja letačkih operacija s bespilotnim letjelicama potrebno se pridržavati određenih pravila. Drugi dio pravilnika se odnosi na pravila letenja. U njemu su nabrojani opći uvjeti letenja bespilotnih zrakoplova.

Rukovatelj mora osigurati da se let bespilotnog zrakoplova izvodi na način da ne predstavlja opasnost po život, zdravlje ili imovinu ljudi zbog udara ili gubitka kontrole nad sustavom bespilotnog zrakoplova i da ne ugrožava ili ne ometa javni red i mir. Rukovatelj mora osigurati da se let bespilotnog zrakoplova odvija danju. Prije samog leta potrebno je provjeriti i uvjeriti se u ispravnost sustava bespilotnog zrakoplova. Bitno je prikupiti sve potrebne informacije za planirani let i uvjeriti se da meteorološki i ostali uvjeti u području leta osiguravaju sigurno izvođenje leta. Bespilotna letjelica može imati na sebi posebnu opremu ili teret koji je potrebno osigurati i pravilno



pričvrstiti da ne dođe do njegovog ispadanja. Prilikom polijetanja i slijetanja potrebno je osigurati da bespilotna letjelica nadvisuje sve prepreke. Kao jedan od uvjeta sigurnosti je da se bespilotna letjelica ne smije približiti na udaljenost manju od 30 metara od ljudi, životinja, objekata, vozila, plovila, drugih zrakoplova, cesta, željezničkih pruga, vodenih putova ili dalekovoda. Ukoliko u blizini područja izvođenja letačkih operacija postoji skupina ljudi, letjelica ne smije prići bliže od 150 metara toj skupini. Bespilotna letjelica mora cijelo vrijeme biti unutar vidnog polja rukovatelja in a udaljenosti ne većoj od 500 metara od njega. Cijela letačka operacija mora biti izvođena izvan kontroliranog zračnog prostora i na najmanje 3 kilometra udaljenosti od aerodroma. Tijekom leta ne smiju se izbacivati predmeti s bespilotne letjelice [7]. Neke od bitnijih pravila sigurnosti možemo vidjeti na slici 9.

Prije izvođenja letačkih operacija kategorija A i B operater koji upravlja bespilotnom letjelicom treba Agenciji dostaviti izjavu koja je propisana Pravilnikom. Za izvođenje letačkih operacija kategorije C treba osim dostave Izjave izraditi operativni priručnik. Letačke operacije kategorije D smiju se izvoditi ako je prethodno ishođeno odobrenje Agencije.



Slika 9. Pravila sigurnosti prilikom rukovanja bespilotnom letjelicom [23]

Za izvođenje letačkih operacija operater koji upravlja ima zadan niz obveza koje treba ispuniti. Mora imenovati odgovornu osobu koja ima ukupnu odgovornost nad aktivnostima operatera. Obvezan je uspostaviti sustav izvješćivanja o događajima povezanim sa sigurnošću u zračnom prometu. Jedna od važnijih zadaća operatera je

vođenje i čuvanje zapisa o letu koji sadržava najmanje sljedeće podatke: datum leta, vrijeme početka i završetka izvođenja letačkih operacija i trajanje leta, ime i prezime rukovatelja koji je obavio let, lokacija izvođenja letačke operacije, klasifikacija područja letenja, operativna masa bespilotnog zrakoplova, napomene o događajima za koje operator procijeni da su od značaja za izvođenje letačkih operacija. Ti zapisi o letu moraju se čuvati najmanje dvije godine. Prije izvođenja operacija kategorije C ili D operator mora procijeniti da li je potrebno provesti aktivnosti upravljanja rizicima. U slučaju da je potrebno provođenje upravljanje rizicima ono mora sadržavati identifikaciju opasnosti, procjenu rizika kao i, ukoliko je potrebno, mjere za smanjenje rizika na prihvatljivu razinu. Zapisi o upravljanju rizicima moraju se također čuvati najmanje dvije godine od datuma prestanka operacija na koje se odnose.

Operativni priručnik mora sadržavati minimalno sljedeće dijelove i upute: sadržaj, status izmjena i listu važećih stranica, dužnosti i odgovornosti osoblja, standardni operativni postupci, održavanje sustava bespilotnog zrakoplova, postupci u nuždi, ograničenja za izvođenje letačkih operacija, izvješćivanje, upravljanje rizicima, osposobljenost rukovatelja, vrste i rokovi čuvanja zapisa.

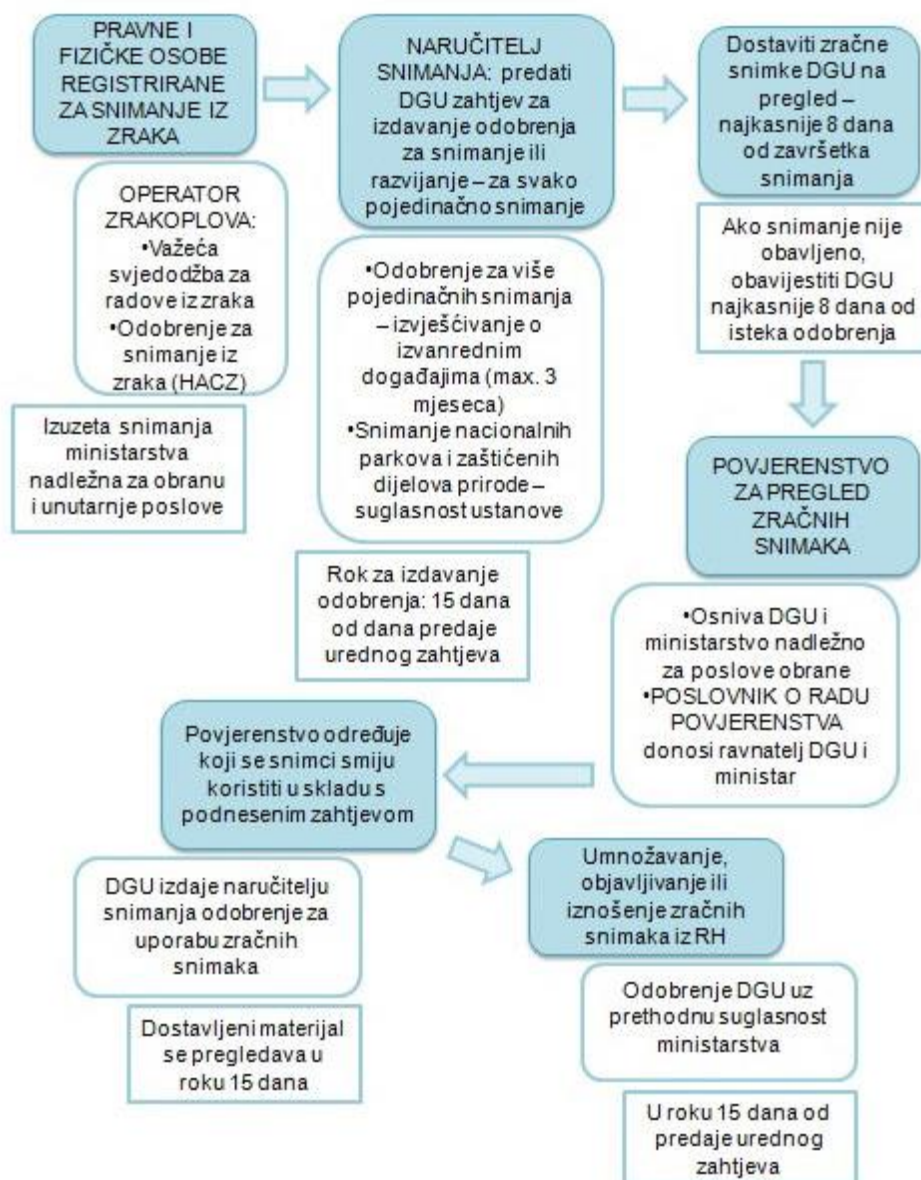
Operator koji namjerava izvoditi letačke operacije izjavljuje da je sposoban i da ima sredstva za preuzimanje odgovornosti povezanih s izvođenjem letačkih operacija sustavom bespilotnih zrakoplova, da sustavi bespilotnih zrakoplova kojima namjerava izvoditi letačke operacije ispunjavaju primjenjive tehničke zahtjeve, te da će letačke operacije izvoditi u skladu s odredbama Pravilnika. Kada je potrebno ishoditi odobrenje za izvođenje letačkih operacija sustavom bespilotnog zrakoplova operator mora agenciji dostaviti sljedeće stavke: ime i adresu podnositelja zahtjeva, opis namjeravanih letačkih operacija, broj i tipove sustava bespilotnih zrakoplova koje će koristiti u izvođenju letačkih operacija u okviru traženog odobrenja, dokaze o ispunjavanju operativnih i tehničkih zahtjeva za izvođenje letačkih operacija, fotografije sustava bespilotnih zrakoplova koji će se koristiti, dokumentaciju procjene rizika namjeravanih letačkih operacija, operativni priručnik i Izjavu propisanu Pravilnikom za ishođenje odobrenja za izvođenje letačkih operacija kategorije D. Agencija može provesti nadzor operatera i zatražiti izvođenje demonstracijskih letova u svrhu izdavanja odobrenja. Odobrenje se izdaje na rok od dvije godine.

### **3.2. Uredba o snimanju iz zraka**

Ovom uredbom propisuju se uvjeti koje pravne i/ili fizičke osobe moraju ispuniti kako bi mogle snimati iz zraka kopnena područja i vodene površine u Republici Hrvatskoj, razvijati, umnožavati i/ili objavljivati snimljene materijale, postupke i uvjete pod kojima je dopušteno iznositi snimke iz zraka iz Republike Hrvatske te proceduru i način pregledavanja snimaka prije njihovog korištenja. Navedeno je da je zrakoplov za snimanje iz zraka svaki zrakoplov koji se koristi u operacijama snimanja iz zraka uključujući i letjelice bez posade opremljene uređajem za snimanje.

Uredba propisuje da snimati mogu pravne i fizičke osobe koje su registrirane za snimanje iz zraka, pri Trgovačkom sudu. Također i operator zrakoplova mora imati važeću svjedodžbu za radove iz zraka te odobrenje za snimanje iz zraka koje izdaje HACZ. Jedina snimanja koja su izuzeta iz ove Uredbe su ona snimanja iz zraka koja provode ministarstva nadležna za obranu i unutarnje poslove. Snimanje iz zraka može se obaviti tek nakon pribavljenog odobrenja za razvijanje zračnih snimaka. Naručitelj snimanja mora Državnoj geodetskoj upravi – DGU podnijeti zahtjev za izdavanje odobrenja za snimanje ili razvijanje i to za svako pojedinačno snimanje. Odobrenje se može izdati iznimno za više pojedinačnih snimanja u slučaju izvješćivanja o izvanrednim događajima kao što su prirodne nepogode, prometne nesreće i slično. Odobrenje se izdaje na razdoblje od najviše 3 mjeseca. Zahtjev mora sadržavati cijeli niz podataka. Podatke o naručitelju snimanja, podatke o snimatelju i dokaz o registriranoj djelatnosti snimanja iz zraka, podatke o operateru snimanja, podatke o zrakoplovu, podatke o operateru zrakoplova, podatke o izvršitelju razvijanja u slučaju da je različit od snimatelja, podatke o vremenu snimanja, svrhu snimanja, plan snimanja na karti, podatke o vrsti snimanja i mjesto čuvanja snimljenog materijala [8].

Slika 10 i dijagram na njoj pokazuju nam koliko je kompliciran i od koliko se zapravo puno koraka sastoji cijeli proces.



Slika 10. Dijagram postupaka prema uredbi [23]

Nakon obavljenog snimanja zračne snimke se moraju dostaviti Državnoj geodetskoj upravi na pregled. Državna geodetska uprava i ministarstvo nadležno za poslove obrane tada mora osnovati Povjerenstvo za pregled zračnih snimaka koje određuje koji se snimci smiju koristiti u skladu s podnesenim zahtjevom. Zračne snimke se dostavljaju na pregled DGU odmah nakon obavljenog snimanja, a najkasnije u roku 8 dana od završetka snimanja. Ako je izdano odobrenje za snimanje ili razvijanje zračnih snimki, a snimanje nije obavljeno, tada se o tome mora obavijestiti DGU najkasnije u roku 8 dana od isteka odobrenja. Povjerenstvo treba pregledati dostavljeni materijal u roku od 15 dana te donijeti zaključak na temelju kojeg će DGU izdati naručitelju snimanja odobrenje za uporabu zračnih snimaka. Način rada Povjerenstva

propisuju ravnatelj DGU i ministar nadležan za poslove obrane Poslovnikom o radu Povjerenstva.

Na temelju ove Uredbe cijeli proces letačke operacije u kojoj se obavlja i snimanje iz zraka se znatno produžuje. Letačka operacija s bespilotnim zrakoplovom manjih dimenzija, npr. klase 5, većinom je ograničena trajanjem od nekoliko minuta. Planiranje leta, izvođenje letačke operacije i obrada podataka može se u idealnim slučajevima obaviti i u jednom danu (za manja područja). No, za taj jedan dan rada potrebno je, osim imati registriranu letjelicu, operativni priručnik, suglasnost HACZ-a, dozvolu pilota, također pribavljeno i odobrenje DGU te nakon obavljenog snimanja odobrenje za uporabu zračnih snimaka. Što zajedno može potrajati i mjesec dana. Protiv ovakvog strogog načina ishođenja odobrenja i slanja snimaka na pregled izjasnili su se gotovo svi koji već imaju bespilotne letjelice ili ih planiraju nabaviti.

### **3.3. Pregled zakonske regulative u europskim državama**

U ovom dijelu dan je kratki pregled zakona pojedinih država članica Europske Unije koji se odnosi na upotrebu bespilotnih letjelica. Zakoni, uredbe i pravilnici o bespilotnim letjelicama su vrlo slični u svim zemljama u kojima postoje. Baziraju se prvenstveno na sigurnosti. Vlasti su svjesne što se sve može postići upotrebom bespilotne letjelice te se unaprijed pokušavaju spriječiti mnoge nezakonite radnje. Također se pozivaju i na druge zakone poput zakona o zaštiti podataka. Upotreba bespilotnih letjelica s masom iznad 150 kilograma je pod nadležnosti Europske agencije za zračnu sigurnost – EASA (*engl. European Aviation Safety Agency*) pod Uredbom 216/2008/EC u kojoj za bespilotne letjelice vrijede jednaka pravila kao i za konvencionalne zrakoplove s posadom kada se koriste u kontroliranom zračnom prostoru.

Zakon Republike Hrvatske jedan je od najnovijih koji je stupio na snagu i napravljen je po uzoru na zakone u Europi koji već djeluju u drugim državama. Komercijalna uporaba bespilotnih letjelica mase ispod 150 kilograma regulirana je određenim zakonima u jedanaest država članica Europske Unije (izuzev Hrvatske): Austriji, Republici Češkoj, Danskoj, Francuskoj, Njemačkoj, Irskoj, Italiji, Poljskoj, Rumunjskoj, Švedskoj i Ujedinjenom Kraljevstvu. Belgija, Finska, Latvija, Nizozemska i Slovenija još nemaju pravilnike koji bi direktno regulirali komercijalnu upotrebu bespilotnih

letjelica, ali su dopuštene određene letačke operacije koje ovise o pojedinom slučaju. Svakako svaka država ima u planu uvesti regulaciju vezanu za bespilotne letjelice jer njihova uporaba s razvojem postaje neizbježna. Informacije o pravnim regulativama u pojedinim državama članica preuzete su iz Istraživanja o privatnosti, zaštiti podataka i etičkim problemima u civilnim operacijama RPAS-a (remotly piloted aircraft systems – daljinski upravljane letjelice). Ukoliko se bespilotni zrakoplov koristi za sportsko rekreacijske svrhe, a ne komercijalne, tada se naziva zrakoplovni model. Za zrakoplovne modele koji su većinom manje mase vrijede druga pravila i u određenim državama postoje udruženja koja članovima korisnicima pružaju upute, treninge, dozvole i osiguranje (npr. austrijski i talijanski aeroklubovi).

Nacionalne zakonske regulative komercijalne uporabe RPAS-a većinom propisuju kvalifikacije pilota i treninge, zahtijevanu plovidbenost i certifikate, zakonske odredbe operativnih licenci i dozvole za rad u zraku, odgovornost, osiguranje i operative zahtjeve. Iako će možda postojati izuzeće za manje vrste RPAS-ova (mase manje od dva, pet ili sedam kilograma) za sada većina nacionalnih odredaba zahtijeva od komercijalnih operatera prijavu nacionalnim civilnim institucijama za dopuštenje. U većini država pravilnici bespilotnih letjelica propisuju ograničenja ili zabrane za let preko ili blizu gusto izgrađenih i/ili gusto naseljenih područja, skupine ljudi, zračnih luka i ostalih osjetljivih infrastruktura; dok su u nekim zemljama takvi letovi u potpunosti zabranjeni. Zakoni često nameću minimalnu dob pilota od 16 ili 18 godina te se za RPAS-ove većih klasa (s masom iznad 20 ili 25 kilograma) zahtijeva profesionalna pilotska licenca ili RPAS kvalifikacija.

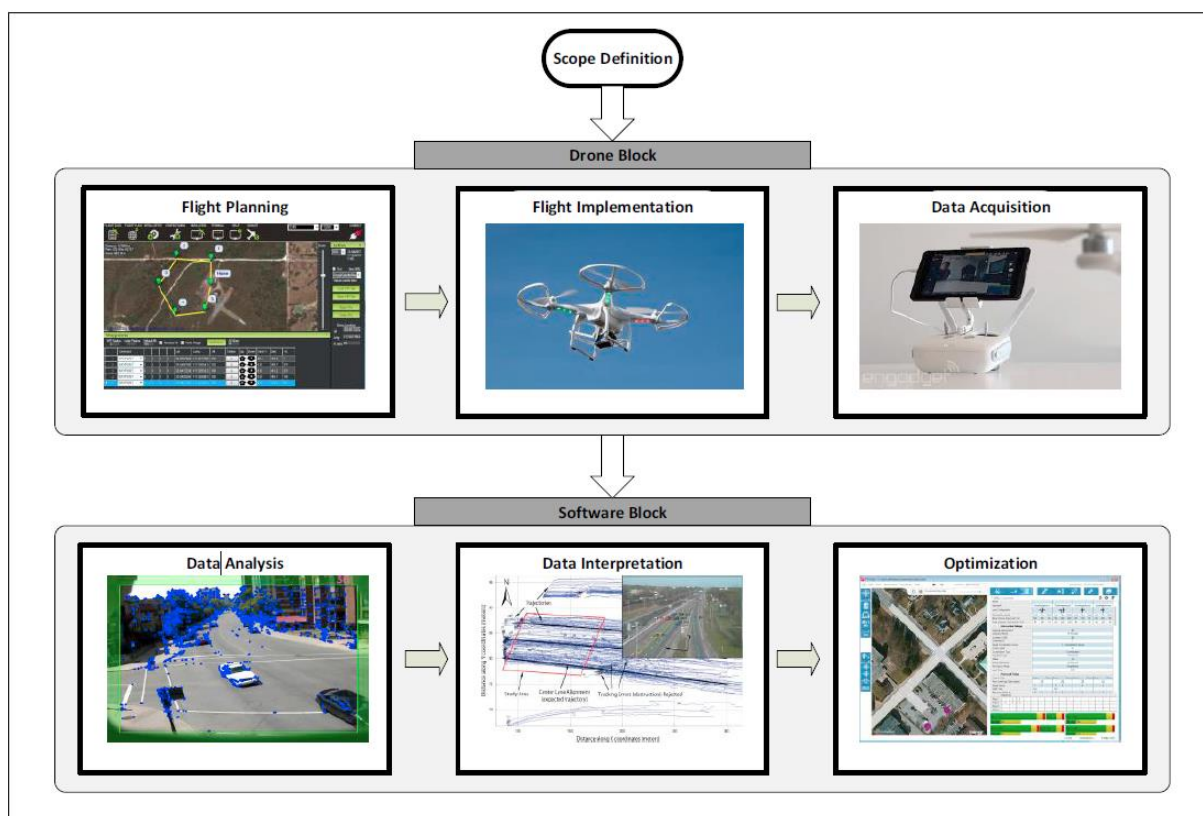
#### **4. Metodologija korištenja bespilotnih letjelica za snimanje prometa u gradovima**

Bespilotne letjelice su jedna od najdinamičnijih tehnologija modernog doba. Nedavno je ta tehnologija pronašla višestruke primjene u području prometa od nadzora prometa pomoću njih pa sve do analize prometnih mreža za cjelokupno poboljšanje protoka i sigurnosnih uvjeta. Postoji niz koraka koje je potrebno zadovoljiti prije samo leta. Neka okosnica je bazirana na već postojećim studijama i klasificirana je u slijedećih sedam komponenti:

1. Definicija opsega djelovanja,
2. Planiranje leta,
3. Izvedba leta,
4. Prikupljanje podataka,
5. Analiza i obrada podataka,
6. Tumačenje podataka,
7. Apliciranje dobivenih rezultata za optimiziranje prometa [9].

Sa ograničenim i skupim infrastrukturnim alternativama, upravljanje prometom je ostalo jedino sa opcijom da se osigura efikasno i optimalno korištenje prometne mreže. U tu svrhu počeli su se primjenjivati ITS sustavi kako bi nadzirali i analizirali prometni sustav. Video sustavi sa bespilotnih letjelica pružaju podatke visoke rezolucije, mogu pokriti velika područja u kratkom vremenu sa ekstremno niskim troškovima i mogu se iznova koristiti na drugim lokacijama.

Kao što vidimo na slici 11, cijeli proces mogao bi se podijeliti u dvije glavne skupine: bespilotna letjelica i software za analizu videosnimaka.



Slika 11. Predložena metodologija [9]

Prema literaturi, bespilotne letjelice se naveliko istražuju za nadzor prometa i evaluaciju prometne mreže. Razni tipovi letjelica se koriste ili testiraju za mjerenje podataka vezanih uz promet na nekoliko sveučilišta. Literatura spominje određen broj prednosti skupa sa barijerama koje bespilotne letjelice trebaju savladati kako bi se uspješno iskoristile za civilnu namjenu.

#### 4.1. Definicija opsega djelovanja studije

Prva komponenta uključuje određivanje opsega studije koja će se provoditi. To je kritičan korak u svakom projektu jer svi kasniji koraci ovise o njemu. Stoga, tokom ovog koraka potrebno je definirati sve ciljeve projekta. U njemu se određuju parametri projekta kao što je tip projekta, izlazni podaci, senzori kamera, tip bespilotne letjelice i ograničenja letenja. Ti parametri mogu varirati od primjene do primjene i postoje neka tri osnovna koraka koje vidimo na slici 12.





Slika 12. Parametri projekta

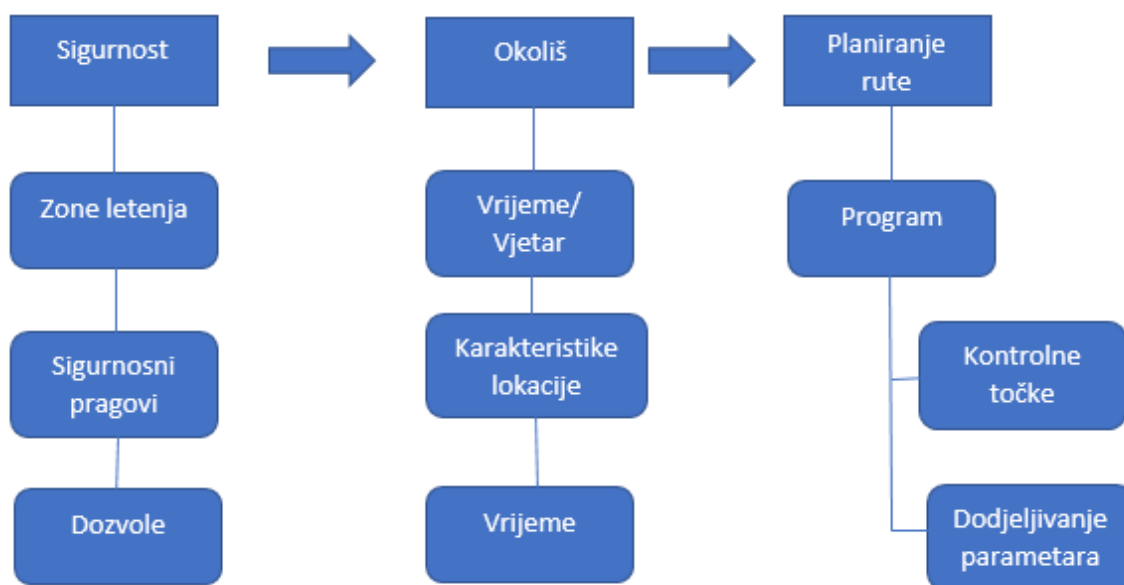
Prije svega određuje se glavni cilj projekta u odnosu na očekivane rezultate studije, Ciljevi mogu uključivati implementaciju novih rješenja u promet kako bi se poboljšao prometni tok ili smanjili prometni incidenti. Nakon toga, u drugom koraku se određuju dijelovi prometne mreže koji će se nadzirati ili analizirati. To mogu biti raskrižja, dijelovi prometnice ili kombinacija obojeg. U posljednjem koraku određuju se parametri bitni za studiju kao što su prometni volumen, pješački volumen, klasifikacija vozila, brzine vozila i dr. Tipovi traženih parametara koji će biti izvedeni iz bespilotne letjelice utječu i na tip leta koji će se provesti, npr. za određivanje putanji vozila u određenom raskrižju dovoljno je ostaviti bespilotnu letjelicu da lebdi (konstantna visina, brzina je jednaka nuli) iznad raskrižja.

#### **4.2. Planiranje leta za prikupljanje podataka pomoću bespilotne letjelice**

Planiranje leta uključuje pripremu za implementaciju stvarnog leta bespilotne letjelice kako bi se prikupili traženi podaci. Sa značajnim porastom broja bespilotnih letjelica formirani su već prije spomenuti zakoni i regulative kako bi se izbjegle veće nesreće. U toj situaciji, planiranje leta bespilotne letjelice postalo je važnije nego ikad.

Prema dosadašnjoj literaturi o nadzoru prometa putem bespilotne letjelice, cijeli proces bi se također mogao podijeliti u tri kategorije (prikazane na slici 13):

- Sigurnost,
- Okoliš,
- Planiranje rute.



Slika 13. Koraci za planiranje leta

Ove tri kategorije uključuje sve aspekte koji su kritični za osiguravanje uspješnog izvođenja letačke operacije. Prije svega procjenjuju se kategorije letačkih zona uz pomoć lokalnih karti letačkih zona. Također, mora se održavati sigurna udaljenost od aktivnih zračnih luka i od ostalih osjetljivih građevina. Bazirajući se na letačkoj zoni, sigurnosnim pragovima i ostalim karakteristikama projekta, mogu se odrediti parametri leta tijekom procesa planiranja leta. To slijedi nabavka letačke dozvole.

Karakteristike lokacije, infrastrukturno okruženje i razmjer izgrađenosti područja u zoni ispitivanja moraju također biti uzeti u obzir za određivanje optimalnih parametara leta. Osim prostornog planiranja za let bespilotne letjelice, potrebno je i vremensko planiranje. To zahtijeva posebno razmišljanje u odnosu na vremenske uvjete i vjetar u zoni ispitivanja zajedno sa optimalnim odabirom vremena u danu za snimanje. Na primjer, provoditi let bespilotnom letjelicom u podne jer su sjene minimalne u to doba dana što kao rezultat daje veću kvalitetu i lakšu analizu snimke.

Sa napretkom u tehnologiji, programi za planiranje letova su razvijeni kako bi omogućili više sistematske i automatizirane letačke operacije. Koristeći takve programe korisnici mogu isplanirati i učitati točnu rutu leta na bespilotnu letjelicu za autonoman let.



Slika 14. Mission planner program [24]

Neki od takvih programa su Mission Planner (slika 14) i QgroundControl koji omogućuju označavanje kontrolnih točaka putem željene rute koje bespilotna letjelica zatim slijedi. Međutim, prema donesenim zakonima i u slučaju autonomnog leta potreban je promatrač koji neće ispuštati letjelicu iz vidnog polja te upozoriti ostalo osoblje i operatera ukoliko primijeti odstupanje bespilotne letjelice od planiranog leta.

### 4.3. Izvedba leta bespilotnom letjelicom

Tijekom ovog koraka bespilotna letjelica stvarno leti prema planiranoj ruti leta. Let se izvodi prema zadanim parametrima koji su određeni tijekom faze planiranja leta. Let se može, ovisno o korisnikovom preferiranju, izvoditi manualno putem daljinskog upravljača ili automatski putem autopilota. Ovaj korak u kombinaciji sa planiranjem leta zahtijeva adresiranje određenog broja sigurnosnih i zakonskih problema koji su spomenuti ranije.

Da bi let bio uspješan potrebno je osigurati da se kamera ne trese niti pomiče previše dok se snima video, platforma na kojoj se nalazi kamera mora biti dovoljno

stabilna kako bi se mogao postići video visoke kvalitete. Iz tog razloga većina bespilotnih letjelica sadrži kardanski prsten (slika 15) koji dozvoljava rotaciju kamere oko svake osi.



Slika 15. Kardanski prsten na bespilotnoj letjelici Phantom 4 [25]

Kardanski prsten sadrži svoje senzore pokreta i male motore tako da su pokreti kamere nezavisni u odnosu na pokrete bespilotne letjelice. Operater je u mogućnosti okrenuti kameru u kojem god smjeru želi bez obzira na smjer letjelice.

#### **4.4. Prikupljanje podataka pomoću videosnimke sa bespilotne letjelice**

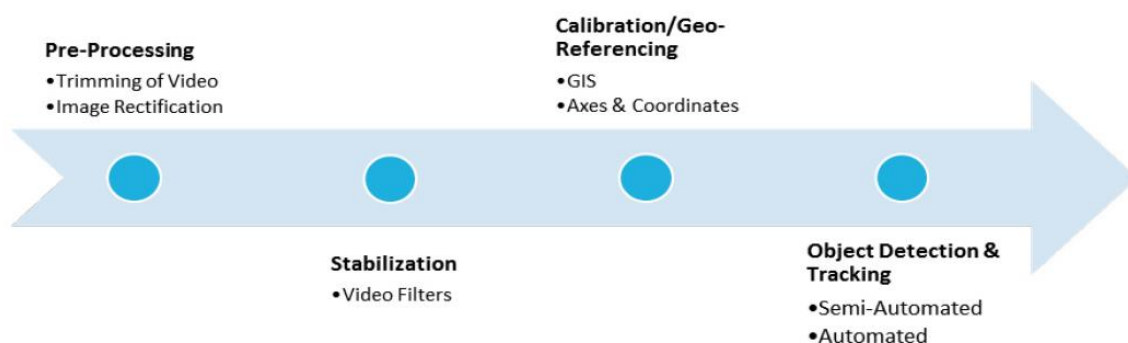
Prikupljanje podataka je od kritičnih koraka u ovoj predloženoj metodologiji. Podaci koji se trebaju prikupiti sa bespilotne letjelice uključuju videosnimku uz ostale podatke sa senzora koji mogu biti montirani na bespilotnu letjelicu (infracrveni, termalni, ultrasonični i dr.). U nekim slučajevima potrebni su i telemetrijski podaci leta (visina, horizontalna brzina, vertikalna brzina, pozicija i smjer u koji je okrenuta letjelica) kako bi se kalibrirao snimljeni video.

Prikupljanje podataka može biti stvarnovremenski i nezavisan, oviseći o zahtjevima projekta. Većina dosadašnjih studija upotrebljava nezavisan pristup u kojem se podaci prikupljaju u procesiraju nakon završetka leta bespilotne letjelice. Stvarnovremensko prikupljanje podataka koristi se prilikom praćenja vozila kako bi se nadziralo i istraživalo ponašanje vozača te smanjile nesreće i povećala sigurnost na

prometnicama. Predloženi sustav se bazira na direktnom prijenosu videa sa bespilotne letjelice na upravljačku jedinicu na zemlji što omogućuje da se slika analizira sa vrlo malim kašnjenjem u odnosu na vrijeme snimanja te slike tj. Videoa.

#### 4.5. Analiza i obrada podataka dobivenih sa videosnimke bespilotne letjelice

Analiza videa privukla je značajnu pažnju uglavnom zato jer omogućuje znanstvenicima lakše prikupljanje detaljnih podataka. Mnogo je istraživanja provedeno u analizi videozapisa sa statičnih kamera, ali analiza prometa sa videa snimljenog putem nestabilne zračne platforme je relativno nova tema. Ovaj proces je puno kompleksniji kada se usporedi sa analizom prometa iz videozapisa statičnih kamera. Više pristupa je bilo primijenjeno u postojećoj literaturi za procesiranje i analizu podataka videosnimke sa bespilotne letjelice. Te pristupe moguće je podijeliti u dvije kategorije: poluautomatska video analiza i automatska video analiza.



Slika 16. Koraci obrade podataka [9]

Međutim, radni slijed za oba pristupa ostaje isti kao što je prikazano na slici 16. Analiza snimke sa bespilotne letjelice započinje sa pripremnom obradom videa kao što je izbacivanje nebitnih dijelova (polijetanje, slijetanja, vrijeme dolaska do željene točke) i stabilizacijskim procedurama kao što su video filteri. Nakon što se slike georeferenciraju započinje detektiranje i praćenje objekata.

#### **4.5.1. Poluautomatska video analiza**

Ovakav poluautomatski pristup je lagano za pripremiti i osigurava visok nivo točnosti i pouzdanosti. Također, nisu potrebni nikakvi kompleksni algoritmi za obradu slike što podrazumijeva da je potrebno i puno manje računalne snage. S druge strane ovaj pristup zahtijeva više rada i ljudske snage jer obilno uključuje određivanje nekih fizičkih kontrolnih točaka na zemlji ili imati točno izmjerene određene dužine na lokaciji kako bi se mogle kalibrirati slike s bespilotne letjelice. Jedan od takvih programa je „Tracker“ koji se često koristi kod studija koje zahtijevaju poluautomatsku video analizu.

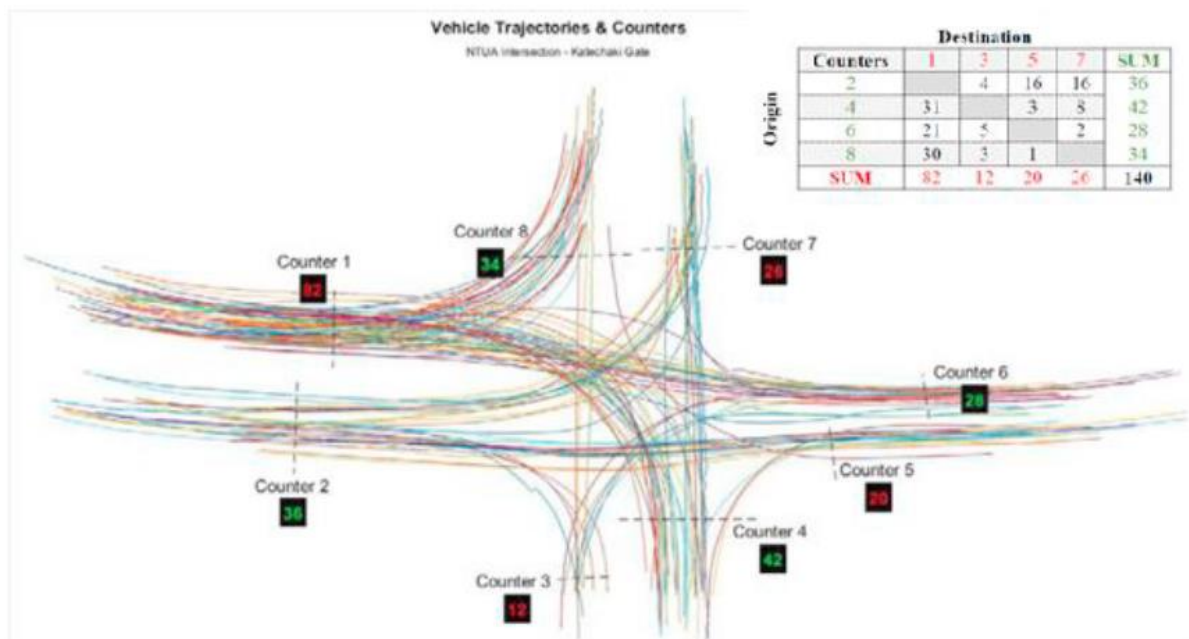
#### **4.5.2. Automatska video analiza**

Automatska analiza prikupljenih podataka putem bespilotne letjelice uključuje niz naprednih filtera i tehnika za obradu slika kako bi se detektirali i pratili prometni korisnici od nekog značaja. Automatska video analiza je sve popularnije zbog svoje primjene kod stvarnovremenog nadziranja i praćenja prometa. Iako je takav pristup brz i zahtijeva minimalnu ljudsku snagu i dalje ima neke ograničenja. Uglavnom je to preciznost takvog sustava koja dramatično varira sa promjena u uvjetima kao što su svjetlost, klimatske promjene i dr. Dodatno, automatski sustav zahtijeva visoku računalnu snagu i teško ga je za postaviti jer uključuje kompleksne algoritme za svaki podzadatak analize.

### **4.6. Tumačenje dobivenih podataka**

Tumačenje podataka iz obrađenog videa je slijedeći korak ovog metodološkog postupka. Tumačenje se radi uz pomoć različitih tipova grafova i dijagrama koji su kreirani kao izlaz podataka iz procedura za analizu. Putanje vozila izvučene tijekom analize se mogu prikazati u x-y ravninskim grafovima kako bi razumjeli ponašanje i

trend korisnika. Slično, takve putanje predstavljaju ilustrativni prikaz kretanja prometa preko raskrižja kao što je prikazano u slici 17.



Slika 17. Prikaz putanji vozila na raskrižju [9]

Poseban fokus se pridodaje putanjama koje bi mogle ugroziti sigurnost prometa. Isto tako iz toga se mogu konstruirati OD (polazno-odredišne) matrice kako bi kvantificirali prometni volumen za svaki prilaz raskrižja. Moguće je odrediti i druge prometne parametre kao što su protok i gustoća prometa, sve ovisi o tome koji su zahtjevi studije.

#### 4.7. Apliciranje dobivenih rezultata za optimiziranje prometa

Određeni prometni parametri tokom analize i tumačenja podataka sa videozapisa bespilotne letjelice su angažirani kako bi poboljšali postojeće prometne modele koji ultimativno pomažu u rješavanju stvarnih svjetskih prometnih situacija. TO može uključivati više prometno vezanih zadataka kao što su: optimizacija signalnog plana, promatranje ponašanja vozača i dr. Stvarno vremenski sustav informirana može optimizirati prometne operacije šaljući upozorenja određenim ustanovama u slučaju incidenata i hitnih situacija.



## 5. Usporedna analiza softwareskih alata i manualnih postupaka za ekstrakciju prometnih veličina iz videozapisa bespilotnih letjelica

Nakon što smo putem bespilotne letjelice snimili željeni segment prometnice ili neko raskrižje potrebno je analizirati videozapis kako bi mogli iz njega izvući tražene prometne veličine i dobivene rezultate primijeniti u nekom rješenju za optimizaciju prometa u snimanoj zoni ili povećanje sigurnosti na tom području.



Slika 18. Snimka dijela prometnice sa bespilotne letjelice

Kako bi došli do traženih prometnih veličina iz neke snimke, kao npr. što je na slici 18, potrebno je analizirati snimku na jedan od slijedeća dva načina: pomoću softwareskih alata ili manualnim putem. Svaka studija ima drugačije zahtjeve te s njima dolazi potreba i za različitim prometnim veličinama koje se traže. Za neke, dovoljno je samo prebrojiti broj vozila na slici dok je za dobivanje drugih potrebno korištenje već poznatih formula (gustoća, prometni tok, razina usluge, prosječni godišnji dnevni promet i dr.). Svaki od ova dva načina koristi drugačije resurse, jedan je star, spor, pouzdan i zahtijeva ljudsku radnu snagu uz malo računalne snage dok je drugi relativno novi koji koristi umjesto ljudske snage snagu računala i razne kompleksne algoritme kako bi mogao izvući tražene veličine i svakim danom postaje sve brži, točniji i pouzdaniji sa sve manjim greškama u analizi.



## 5.1. Softwareski alati za ekstrakciju prometnih veličina iz videozapisa

Danas u procesu naglog razvitka, softwareski alati služe kako bi pomogli i olakšali poluautomatsko ili automatsko analiziranje videozapisa i ekstrakciju prometnih veličina. Njihova prednost je u tome što je zadatak korisnika samo učitati videozapis i odrediti koji se parametri traže dok su svi kompleksni algoritmi koje softwareski alat koristi za detaljno analiziranje slike, kako bi nam isporučio tražene veličine, za nas „nevidljivi“.

Softwareski alat radi umjesto nas niz koraka kako bi nam ispostavio tražene rezultate. Svako analiziranje videozapisa započinje sa uklanjanjem nebitnih dijelova snimke za studiju, a to se može odnositi na polijetanje i slijetanje ili na let bespilotne letjelice do određene zone ili raskrižja koje treba analizirati. Slijedeće što je potrebno od softwareskog alata je da rastavi videozapis na slike jer algoritmi analiziraju niz slika iz kojih izvlače prometne veličine. Tako da alat svake sekunde (ili neki drugi vremenski interval određen od korisnika) uzme jednu sliku iz videozapisa.

Zatim slijedi kalibriranje izvađenih slika i njihovo georeferenciranje. S obzirom da leća na kameri funkcionira na isti način kao i ljudsko oko tj. prikuplja svjetlost, dolazi do iskrivljenja i izobličenja slike na rubovima kamere zbog drugačijeg kuta upada zraka svjetlosti te je potrebno korigirati te nepravilnosti kako bi se dobila realna slika kao što vidimo na slikama 19 i 20.




**Slika 19.** Slika prije kalibriranja [26]



Slika 20. Slika nakon kalibriranja [26]

Nakon što su sve slike ovako kalibrirane i georeferencirane počinje se njihovo međusobno uspoređivanje na bazi piksela. Slijedeći zadatak softwareskog alata je da detektira i prati željene objekte, točnije vozila. Sliku za slikom uspoređuje se svjetlina piksela koji se nalaze na identičnim mjestima u različitim slikama i na taj način se detektira promjena u razini svjetlosti piksela te tako računalo prepoznaje kretanje vozila.



Slika 21. Proces detekcije vozila [27]

Naravno vozilo zauzima više od jednog piksela na slici te je potrebno njihovo grupiranja i detekcija oblika vozila kako bi se smanjile detekcije neželjenih objekata na slici. Isto tako program uči odvajati vozila od linija na prometnicama koje se također mogu detektirati. Na slici 21 možemo vidjeti cijeli proces detekcije vozila i konačan rezultat.

Uz ovakav način detekcije, softwareski alat ima mogućnost brojati i pratiti putanje označenih objekata te na taj način pružiti korisniku prometne veličine sa snimke. Sa grafova i dijagrama dobivenih putem softwareskog alata moguće je pratiti ponašanje korisnika u prometu. Vidjeti postotak agresivnog, normalnog i opreznog ponašanja u prometu. Isto tako moguće je određivanje OD matrica kako bi znali u kojem smjeru se koliko vozila kreće.

Jedno od pitanja koja se povlače za ovakvim načinom analize videozapisa sa bespilotne letjelice je kolika je konačna točnost i broj grešaka u analizi kod ovakvog pristupa. Postoji niz faktora koji mogu umanjiti točnost ovakvog pristupa te je potrebno obratiti pažnju na njih prilikom leta sa bespilotnom letjelicom i snimanja. Prije svega ponašanje bespilotne letjelice je osjetljivo na okoliš u kojemu se testira. Vibracije na videozapisu se povećavaju sa većom brzinom vjetrova te mogu uzrokovati lošiju kvalitetu videozapisa. Dodatno tome, bespilotna letjelica možda neće pravilno funkcionirati u lošim vremenskim uvjetima kao što je magla ili snijeg.

Također, letjelica je ograničena trajanjem baterije. Kao uređaj za nadziranje prometa, kratko vrijeme rada nije sposobno pružiti dosta kontinuiranih podataka za dugotrajno nadziranje dijela prometnice. Sjene imaju negativan učinak na praćenje i detekciju vozila. Kao jedno alternativno rješenje spominju se infracrvene kamere koje bi detektirale i pratile vozilo na temelju njegove topline motora. Snimanje dužih dionica nije moguće jer bi se podizanje bespilotne letjelice na visinu potrebnu da obuhvati cijelo područje uništila kvaliteta slike i ne bi bilo moguće izvući nikakve relevantne podatke iz tog videozapisa.

Na slici 22 bit će prikazani rezultati točnosti iz jednog provedenog istraživanja.

UAV altitude (m)/Road section length(m)	100/190	120/228	150/285
Vehicle average speed (m/s)	12.4	11.2	12.0
True positives	1999	1877	1520
False positives	0	0	0
False Negatives	2	3	61
Correctness	100%	100%	100%
Completeness	99.9%	99.8%	96.1%
Quality	99.9%	99.8%	96.1%

UAV altitude (m)/Road section length (m)	100/190	120/228	150/285
Number of vehicles	1999	1877	1520
Number of "lost vehicle"	0	11	32
Error rate	0%	0.6%	2.1%

**Slika 22.** Prikaz točnosti kod detektiranja i praćenja vozila [27]

Prva tablica na slici se odnosi na točnost u detektiranju vozila dok druga tablica na slici prikazuje točnost kod praćenja vozila. Kao što vidimo sa slike, ukoliko se ispoštuju mogućnosti bespilotne letjelice u smislu njenog korištenja za vrijeme povoljnih vremenskih uvjeta moguće je dobiti vrlo visoku točnost. Možemo primijetiti kako i bez obzira na povoljne vremenske uvjete broj grešaka raste sa većom visinom bespilotne letjelice i većim područjem snimanja. I kroz ostalu pronađenu literaturu na temu točnosti analize snimaka, broj grešaka nije prelazio nikada više od 4%.

#### **5.1.1. Picomixer STA**

Picomixer je softwareski alat za video analizu prometa i brojanje vozila. Služi kako bi se detektirale incidentne situacije, prikupili prometni podaci i poboljšali sigurnosni uvjeti bazirani na dobivenim podacima iz videozapisa.



Slika 23. Korisničko sučelje programa Picomixer STA [10]

Neke osnovne mogućnosti picomixera su:


- Automatska analiza prometa koristeći video analizu.
- Brojenje i klasifikacija vozila po kategorijama i po smjeru.
- Računanje trenutnog prometnog volumena i prosječnog prometnog volumena.
- Računanje prosječne brzine vozila.
- Detektiranje incidenta u obliku:
  - Zaustavljenih vozila,
  - Vozila koja se kreću u krivom smjeru,
  - Detektiranje neobilnih promjena u volumenu prometa,
  - Detektiranje neobičnih promjena u brzini vozila.
- Pružanje izvješća u raznim oblicima; grafovi, dijagrami, tablice.
- Mogućnost rada u stvarnovremenskoj povezanosti s kamerom.
- Mogućnost prilagođavanja promjenama vremenskih uvjeta.
- Mogućnost korištenja videa sa različitih izvora uključujući sve standardne tipove IP kamera i analognih kamera [10].



### 5.1.2. DataFromSky


DataFromSky je novo specijalizirano rješenje za automatsku analizu videozapisa snimljenih iz zraka. Pruža mnoge nove mogućnosti u području analize prometa sa svojim potpuno automatskim izračunima širokog asortimana prometnih veličina kao što su brzina, gustoća i sl. DataFromSky je baziran na automatskom izvlačenju vremensko-prostornih putanja vozila iz videozapisa. Sve veličine su dobivene preko napredne računalne analize video podataka. Ti videozapisi za analizu mogu biti snimljeni i običnom kamerom na bespilotnoj letjelici. Nije potrebna nikakva skupa oprema ili sofisticirani senzori. Zahvaljujući dugotrajnom razvitku i efikasnim algoritmima za detekciju i praćenje za zračnu analizu. Software pruža rezultate visoke kvalitete i potpuno je automatiziran te je sposoban učiti na svojim greškama i ispravljati ih s vremenom [11].

Brojenje vozila je osnovan zadatak u ovakvom softwaru. Kako bi se promet brojao potrebno je zadati neku virtualnu liniju koja registrira svako vozilo koje prijeđe preko nje i automatski bilježi podatke o protoku i brzinama. Kod raskrižja, postavljanjem ulaznih i izlaznih virtualnih linija možemo vrlo lako dobiti podatke o tome kuda se koje vozilo kreće tj. OD matricu kao što je prikazano na slici 24.



Slika 24. Dobiveni podaci o broju vozila po određenom smjeru kretanja [11]

Prometni inženjeri i istraživači trebaju pouzdane i detaljne brojeve o svim aspektima prometnog toka. Analiza putanji vozila je preporučena kao tehnika za računanje karakteristika vezanih uz prometni tok. DataFromSky je sposoban mjeriti prometni tok u bilo kojem području analizirajući putanje vozila u toj zoni. Moguće je odrediti zauzetost prometnice, gustoću i protok na traženom području (slika 25).



Slika 25. Dijagram prometnog opterećenja [11]

Omogućeni su nam detaljni podaci o brzini i akceleraciji za sva vozila praćena u videozapisu. Podaci su dostupni za vrijeme praćenja vozila. Kako vozilo prolazi kroz cijelo promatrano područje tako su odmah i vidljivi podaci o njegovoj brzini i akceleraciji. Točnost se pokazala vrlo visokom u odnosu na druge metode. Metoda za mjerenje brzine i akceleracije DataFromSkya mnogo je superiornija u odnosu na druge. Preciznost i područje pokrivenosti mogu biti samo uspoređeni sa kolekcijom takvih podataka iz senzora svakog zasebnog vozila.

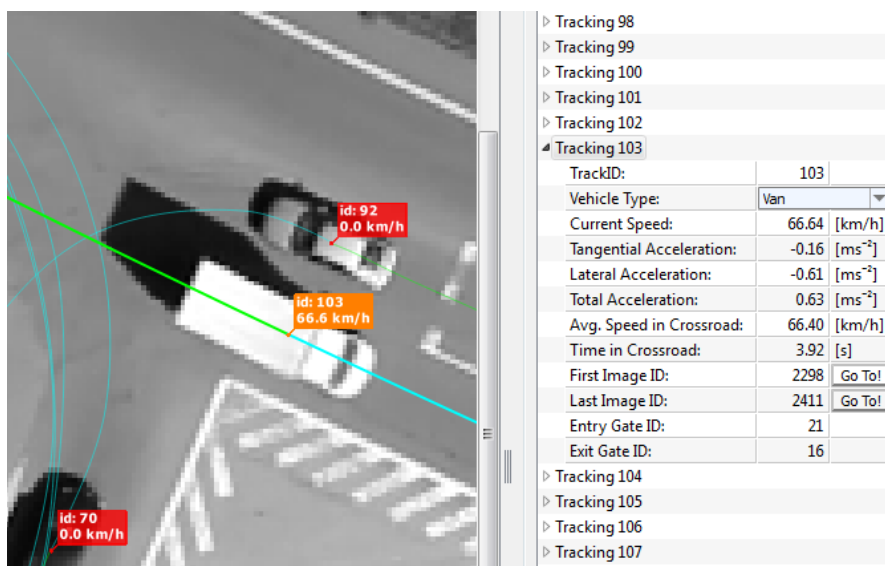


Slika 26. Prikaz mjerenja brzina [11]

Postoji mnogo vrsti vozila na svijetu i velik broj načina je određen kako razlikovati vozila (težina, veličina i dr.). DataFromSky ima određen broj osobina koje uvelike pomažu u tom aspektu:

- Svako praćeno vozilo može biti klasificirano.
- Moguće je definirati nove kategorije klasifikacije.
- Virtualne linije mogu biti postavljene tako da broje samo određene tipove vozila.
- Analiza prometnih parametara može biti ograničena samo na izabrane tipove vozila.


Postoji i jedan razumljiv nedostatak zbog korištenja zračnih snimki, a to je da se ne mogu kategorizirati vozila prema broju osovina.



Slika 27. Primjer klasifikacije vozila [11]

Jedno od važnih područja u svim industrijama danas je zaštita okoliša, pa tako i u prometu. Emisije štetnih plinova iz vozila uvelike pridonose zagađenju zraka, pogotovo u urbanim područjima kao što su veliku gradovi. Prometne mreže zahtijevaju i drugačiji aspekt gledanje jer ne utječu samo na sudionike u prometu već i na stanovnike.





**Slika 28.** Prikaz područja emisija štetnih plinova [11]

Velik broj podataka je potreban kako bi se točno procijenila količina štetnih plinova iz ispušnog sistema vozila. Korištenjem podataka o tipu vozila, brzini i ubrzanju i spajanjem tih podataka sa prosječnim stvaranjem štetnih plinova pojedinog motora raznih tipova vozila mogu se dobiti okvirni podaci o emisiji štetnih plinova sa videozapisa.

## **5.2. Manualna ekstrakcija prometnih veličina iz videozapisa**

Manualna ekstrakcija, osim samog videozapisa, uključuje ljudski napor koji je potreban kako bi obradili i analizirali snimku te izvukli prometne veličine iz nje. Iako je to pouzdan način analize sa velikom točnošću, najveći nedostatak mu je što je spor. Potrebna je osoba ili više osoba koje će pregledavati snimku i bilježiti u npr. excel podatke sa snimke. Za bilo kakav kompleksniji podatak prometnog toka potrebno nam je prvo ručno izvući osnovne podatke kako bi primjenom formula u excelu mogli doći do njih.

Osnovni podaci odnosili bi se prije svega na broj vozila, zatim bi bila potreba klasificirati vozila po kategorijama (osobna, teška, motocikli itd.), po smjeru kretanja kako bismo mogli odrediti polazno odredišnu matricu i prometno opterećenje po pojedinom toku. Ljudska osoba je ograničena u mogućnostima praćenja više vozila odjednom i bilježenja svih ovih osnovnih podataka.

Za kompleksnije podatke potrebno je kroz excel povezati osnovne podatke preko formula koje je potrebno ručno unijeti kako bi mogli dobiti podatke tipa gustoće, prometnog toka, prosječnog dnevnog prometa i dr. Ukoliko nam je potrebna brzina vozila potrebno je odrediti dvije točke na prometnici između kojih znamo točno udaljenost i zabilježiti vrijeme snimke kada je vozilo došlo na prvu točku, te zabilježiti vrijeme snimke kada vozilo stigne do druge točke i tako posebno za svako vozila. Uz pomoć udaljenosti i razlike u vremenu snimaka moguće je odrediti brzinu kojom se vozilo kretalo.

Uzmimo u obzir da trenutno ovom postupku ekstrakcije podataka ide u prilog kratko trajanje leta zbog baterija na bespilotnim letjelicama. Dolazi se do toga da bi mogli u prosjeku imati snimke trajanja od samo kojih desetak minuta što znači vjerojatno na stotine vozila u snimci. Kada se uzme broj vozila u obzir i činjenica da ljudska osoba ne može pratiti više vozila u isto vrijeme, postaje malo jasnije koliko je to dugotrajan i zamoran posao čak i ako imamo za analizirati samo jednu snimku.

## 6. Mjerenje razine usluge i procjena PGDP-a na području užeg središta Sesveta (Zagrebačka cesta)

Bespilotna letjelica napravila je snimak duž glavne prometnice 600 m zapadno prema gradu od križanja Zagrebačke i Varaždinske, te centralno na glavnom križanju Zagrebačke i Bistričke ceste u radijusu od 200 m (slika 29). Trajanje snimka na promatranoj lokaciji iznosilo je 30 minuta. Video snimke uzete na navedenoj lokaciji iskorištene su za istraživanje gustoće prometa i prosječnog godišnjeg dnevnog prometa (PGDP-a), odnosno odražavaju trenutnu situaciju i dugoročne prometne uvjete. Gustoća (vozila/km) koristi se za mjerenje razine usluge prometa, dok se protok (vozila/sat) koristi za procjenu PGDP-a. Kao što je objašnjeno u nastavku, razvijene su dvije različite metode za procjenu gustoće i protoka prometa. Prva metoda koristi fiksne kadrove (mirni okvir), a druga metoda iskorištava informacije dobivene od niza kadrova proizašlih iz zračne snimke generaliziranih i definiranih vremenskom i prostornom dimenzijom [12].



Slika 29. Dionica glavne prometnice Zagrebačke ceste između dva križanja

## 6.1. Metoda 1. Gustoća i protok iz fiksnih kadrova

Broj osobnih i teretnih vozila može se dobiti izravno još iz video snimka. S obzirom na ove brojeve i duljinu kolnika snimljenog u segmentu fotografije, gustoća prometa može se definirati kao:

$$k = \frac{PC+TR*1,5}{L} \quad (1)$$

gdje je,

L = duljina kolnika (segmenta) u km

PC = broj osobnih automobila u snimljenom dijelu segmenta

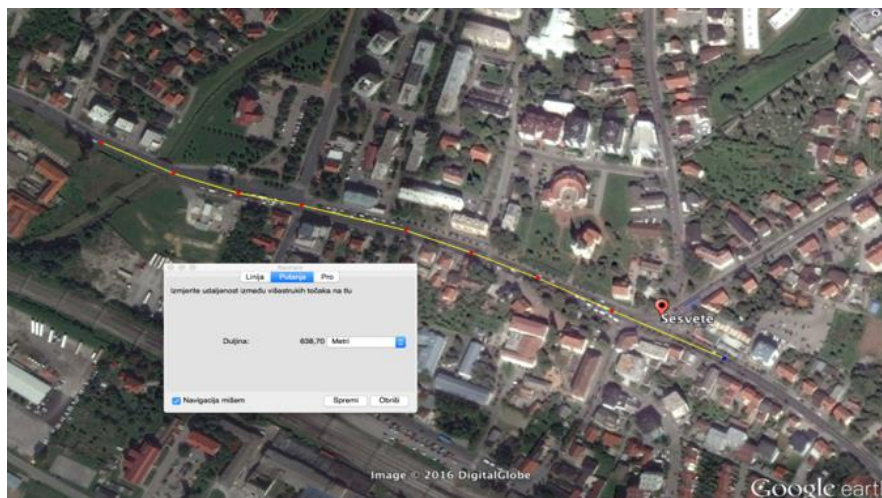
TR = broj teretnih vozila u snimljenom dijelu segmenta.

Ovdje je najteži dio bilo točno mjerenje duljine kolnika (L). Za potrebe ove studije koristili smo zračne fotografije i geoportal Zagrebačke županije i Google earth za mjerenje udaljenosti između promatranih točaka (slika 30). Nedvojbeno kamera na bespilotnoj letjelici se može kalibrirati tako da udaljenost od zemlje i razdaljine na zemlji mogu biti mjerljive iz mirnih kadrova i dobivenih fotografija. U svakom slučaju, s obzirom na gustoću izračunatu u jednadžbi 1, satni volumen se može procijeniti iz fundamentalne jednadžbe:

$$q^H = k * \bar{v} \quad (2)$$

gdje je,

$\bar{v}$  = prostorna brzina



Slika 30. Primjer određivanja udaljenosti između promatranih točaka na dionici ceste

Iako se brzina ne može mjeriti samo od jednog fotografijskog okvira, ona može biti kasnije ustanovljena iz ograničenja brzine na promatranoj dionici ili iz video snimka bespilotne letjelice. U ovoj studiji korištena su dva pristupa za procjenu brzine. Prvi pristup procjene brzine je upotrebom GIS-a za mjerenje udaljenosti između dvije vidljive točke dobivene iz fotografijskog okvira. Tada je korišten video snimak za mjerenje vremena putovanja duž cijelog promatranog segmenta za što veći broj vozila. Prostorna brzina tada je procijenjena kao aritmetička brzina svih izmjerenih brzina duž promatranog segmenta.

$$\bar{v} = \frac{1}{m} \sum_{i=1}^m \frac{L}{t_i}$$

gdje je,

$t_i$  = vrijeme putovanja  $i$ -tog vozila u segmentu duljine  $L$

$m$  = ukupan broj vozila

Drugi pristup procjene brzine kretanja vozila upotrebljava se kada je otežano ili nemoguće uskladiti početak i kraj segmenta sa markerima u GIS-u. U ovom slučaju odabrali smo nekoliko vozila nasumice iz dobivenog fotografijskog okvira. Svako vozilo je praćeno izvjesno vrijeme (nekoliko sekundi), brojali smo trake markera koji su prošli i bilježili vrijeme putovanja. Još jednom, prostorna brzina procijenjena je aritmetička sredina izmjerenih brzina, tj.

$$\bar{v} = \frac{1}{m} \sum_{i=1}^m \frac{n_i l}{t_i}$$

gdje je,

$n_i$  = broj trake markera koje je  $i$ -vozilo prošlo

$l$  = udaljenost od početka trake jednog markera do početka drugog

$t_i$  = vrijeme putovanja  $i$ -tog vozila

## 6.2. Metoda 2. Gustoća i protok iz serijskih okvira

U bilo kojem trenutku senzor bespilotne letjelice prati određeni dio ceste, odnosno promatrane dionice. Normalne fluktuacije u prometu mogu uzrokovati velike varijacije u gustoći prometa mjerene pomoću fiksnih fotografskih okvira. Upotreba fiksnih okvira za proračun gustoće odbacuje mnoštvo informacija koje bi se mogle dobiti upotrebom video snimka. Kako bespilotna letjelica nadlijeće opservacijsko područje duže vremena i na određenoj udaljenosti, vidno polje se stalno mijenja, što ima za posljedicu težu mjerljivost konvencionalne gustoće i toka. Generalizirana definicija prostorno-vremenskog može akomodirati vidno polje koje se stalno mijenja. Za promatrano područje (A) prostorno-vremenske dimenzije: gustoća, protok i prostorna brzina mogu se definirati kao:

$$q(A) = \frac{d(A)}{|A|} \quad (5A)$$

$$k(A) = \frac{t(A)}{|A|} \quad (5B)$$

$$\bar{v}(A) = \frac{d(A)}{t(A)} \quad (5C)$$

gdje je:

$d(A)$ = ukupna udaljenost putovanja svih vozila u području A

$t(A)$ = ukupno vrijeme putovanja svih vozila za područje A

$|A|$  = područje A u prostorno-vremenskoj dimenziji

Upotrebom videa snimljenog duž dionice Zagrebačke ceste, putanje vozila konstruirane su za kretanje prometa u zapadnom smjeru (prema gradu) u intervalima od 2 sekunde koristeći pozicije izračuna iz GIS-a. Ovaj postupak se ponavlja za svaku traku zasebno. Na sličan način je vidno polje (FOV) za taj dio prometa izvučen iz videa i analiziran u prostorno-vremenskoj dimenziji prikazuje nastale putanje za trake i vidno polje mjereno u 20 sekundi. U slučaju da vozilo izađe iz vidnog polja prije opservacije, putanje su produžene linearno do vidnog polja, što je i prikazano crtkanim linijama većine putanja. Protok i gustoća opservacijskog područja izvučeni iz vidnog polja i putanje kretanja vozila mogu se prikazati jednadžbom(5A-B). U stvari putanje vozila se ne trebaju primjenjivati, samo mjesta i vremena gdje vozila ulaze i izlaze iz vidnog

polja. Jedino je bitno razlikovati ulaze i izlaze iz opservacijskog područja, bez praćenja vozila kroz vidno polje.

$$d(FOV) = \sum_i (X_{exit}(i) - X_{enter}(i)) = \sum_i X_{exit}(i) - \sum_i X_{enter}(i)$$

$$t(FOV) = \sum_i (t_{exit}(i) - t_{enter}(i)) = \sum_i t_{exit}(i) - \sum_i t_{enter}(i)$$

gdje  $i$ -to vozilo ulazi u vidno polje (FOV) na  $(X_{enter}(i), t_{enter}(i))$  i izlazi iz vidnog polja na  $(X_{exit}(i), t_{exit}(i))$ . Granice vidnog polja moraju biti specificirane i točne kako bi se moglo izmjeriti precizno  $|FOV|$ . Jednadžbe 6A i 6B mogu se sumirati duž individualne trake, ili za cijelu dionicu ceste neovisno o broju traka i broju smjerova u kojem se vozila kreću.

### 6.3. Procjena PGDP-a

Korištenjem prosječne gustoće u svim trakama s obje metode (jednadžba 1 ili jednadžba 5B), razina prometne usluge može se odrediti direktno iz tablice 2. (prilagođeno iz [13]). Mjerenjem gustoće sa fiksnih fotografskih okvira sa slike 29 i serijskog video zapisa razina prometne usluge zapisana je u tablici 3.

PGDP se procjenjuje prema metodologiji [14],[15], odnosno satnog volumena gdje je prethodno obrazloženo (u ovom slučaju jednadžbe 2 i 3 ili jednadžba 5A).

$$PGDP = q^H * F^{15-16} * 24 * F^{Sub,Pro} \quad (7)$$

gdje je,

$F^{15-16}$  = vrijeme dana kada je snimljen video

$F^{Sub,Pro}$  = dan i mjesec kada je snimljen video

Naravno procjene iz jednadžbe 2 i 7 su pomalo komotne. Tablica 3. pokazuje procijenjeni  $q^H$  svake od fiksnih fotografskih okvira za promatranu dionicu ceste sa rasponom od najveće do najmanje vrijednosti PGDP-a od 2300 vozila/h do 18000 /dan. Usporedbe radi metoda fiksnih fotografskih okvira lakša je u primjeni, ali ono što je čini problematičnom jest mala veličina uzorka svakog pojedinog okvira. Relativno kratke sekcije kolnika korištene u svakoj procjeni gustoće i protoka korištenjem ove

metode mogu pojačati bilo kakve nepravilnosti u fluktuaciji prometa, okolne greške koje se stapaju sa krajolikom, točke vozila i ostale greške. Te pogreške su glavni čimbenik u varijabilnosti između procjene okvira PGDP-a.

**Tablica 2.** Razina usluge klasificirana rasponom gustoće (vozilo/km/traka)

RAZINA USLUGE	BAZIČNI SEGMENTI
<b>A</b>	0-7
<b>B</b>	7-11
<b>C</b>	11-16
<b>D</b>	16-22
<b>E</b>	22-28
<b>F</b>	preko 28

**Tablica 3.** Rezultati istraživanja parametara prometnog toka dionice Zagrebačke ceste po metodama

			Gustoća		q <sup>H</sup>	PGDP
	Okvir	Segment	(Voz/km/traka)	LOS	(Voz/sat)	(Voz/dan)
<b>Metoda 1</b>	1		25,08	E	2356	26,041
<b>Metoda 1</b>	2		28,02	F	2486	
<b>Metoda 2</b>	1		26,42	E	2478	
<b>Metoda 2</b>	2		29,66	F	2691	
<b>PGDP</b>						

U tablici 3. prikazani su rezultati istraživanja opservacije dionice Zagrebačke ceste u Sesvetama primjenom bespilotne letjelice. U analizi parametara prometnog toka predmetne dionice korištene su dvije metodologije. Rezultati pokazuju da analizom parametara prve metodologije (fiksnih fotografskih okvira) odstupaju od dobivenih rezultata po drugoj metodologiji (snimak) u prosjeku za oko 5 %. Može se zaključiti da je analiza snimka dobivena primjenom bespilotnih letjelica znatno učinkovitija metoda u prikupljanju podataka i analizi parametara prometnog toka nego li metoda fiksnih fotografskih okvira. Konkretni su i rezultati glede razine usluge i prometne opterećenosti na analiziranim raskrižjima posebno u vršnom satu, gdje se stvaraju veliki zastoji i nastaju repovi čekanja.



## 7. Zaključak

Razvoj bespilotnih letjelica nekontrolirano gazi prema naprijed i iz dana u dan dolaze na tržište novi i bolji sustavi letjelica. Od velikog značaja je i napredak u području autonomnog leta bespilotne letjelice sa raznim senzorima kako bi taj let učinili sigurnim kada naiđe na neke prepreke. Zbog toga ni ne čudi da je njihova primjena pronasla svoje mjesto u raznim područjima industrije.

Potencijalne mogućnosti primjene i dostupnost tehnologije su omogućile da se strogo vojne letjelice prenamijene u civilnu svrhu. Razvoj računalne, senzorske i komunikacijske tehnologije, razvoj lakih materijala uzrokovali su povećani interes za primjenom bespilotnih letjelica u širokom krugu civilnih aplikacija

Bespilotne letjelice uz pomoć sustava i senzora visoke tehnologije, u kombinaciji s ITS-om, mogu pružiti, uporabom već razvijenih softwareskih alata, puno brže informacije u obliku prometnih veličina koje ako se prikupljaju klasičnim metodama puno duže traju i zahtijevaju puno veće financijske izdatke uz puno više potrebnog osoblja kako bi se podaci prikupili.

Primjena bespilotnih letjelica u području analize prometa u gradovima pruža nove mogućnosti za brži i bolji nadzor prometa. Iako je to još sve u fazi istraživanja, jednog dana ovakve metodologije primjene bespilotnih letjelica pružat će mogućnost stvarnovremenskog nadzora prometa i trenutnog reagiranja na novonastale situacije koje bi mogle smanjiti razinu usluge ili sigurnost na nekom dijelu prometne mreže.

Kako će se sve više razvijati to područje tako će i njihova primjena postajati sve učestalija. U tom periodu će se vjerojatno i iskristalizirati situacija sa zakonima i regulativama te će biti vremenski manje potrebo za doći do dozvola za obavljanje istraživanja i studije nego što je to sada. Iako je njihova primjena u dosta područja još uvijek u istraživačkim fazama, ta istraživanja pokazuju kako bespilotne letjelice sa sobom donose i bolje rezultate u tim područjima te možemo očekivati da će uskoro postati normalna pojava na nebu iznad nas.

## 8. Literatura

- [1] T. Jiang, J. Geller, D. Ni, J. Collura. Unmanned Aircraft System traffic management: Concept of operation and system architecture. Amherst. University of Massachusetts. 2016.
- [2] M. Velzek. Primjena bespilotnih letjelica u sustavu civilne zaštite. Zagreb. Fakultet prometnih znanosti. 2005. Diplomski rad.
- [3] European aviation safety agency. Concept of operations for drones. Cologne. Njemačka. 2015.
- [4] D. Papić. Mogućnost primjene bespilotnih letjelica u Republici Hrvatskoj. Zagreb. Fakultet prometnih znanosti. 2011. Diplomski rad.
- [5] URL:<https://www.microdrones.com/en/applications/areas-of-application/unmanned-cargo/>; (pristupljeno: srpanj, 2017).
- [6] URL:<https://www.microdrones.com/en/applications/areas-of-application/monitoring/>; (pristupljeno: srpanj, 2017.)
- [7] URL:[http://narodne-novine.nn.hr/clanci/sluzbeni/2015\\_05\\_49\\_974.html](http://narodne-novine.nn.hr/clanci/sluzbeni/2015_05_49_974.html); (pristupljeno: srpanj, 2017.)
- [8] URL:[http://narodne-novine.nn.hr/clanci/sluzbeni/2016\\_07\\_70\\_1666.html](http://narodne-novine.nn.hr/clanci/sluzbeni/2016_07_70_1666.html); (pristupljeno: srpanj, 2017.)
- [9] M. Arsalan Khan, W. Wctors, T. Bellemans, D. Janssens, G. Wets. UAV – Based Traffic Analysis: A Universal Guiding Framework Based on Literature Survey. Belgija. Hasselt University. 2016.
- [10] URL:<https://www.picomixer.com/STA.html>; (pristupljeno: srpanj, 2017.)
- [11] URL:<http://datafromsky.com/>; (pristupljeno: srpanj, 2017.)
- [12] L. Edie. Discussion of Traffic Stream Measurements and Definitions. Proc. 2nd International Symposium on the Theory of Traffic Flow. 1963. pp 139-154.
- [13] I. Dadić, G. Kos, M. Ševrović. Teorija prometnog toka. Zagreb. Fakultet prometnih znanosti. 2014.
- [14] M. McCord, Y. Yang, Z. Jiang, B. Coifman, P. Goel. Estimating AADT from Satellite Imagery and Air Photos: Empirical Results. Transportation Research Record 1855. 2003. pp 136-142.
- [15] Z. Jiang, M. McCord, P. Goel. Improved AADT Estimation by Combining Information in Image- and Ground-based Traffic Data. ASCE Journal of Transportation Engineering. 2005.

- [16] URL:<http://didbantech.com/wp-content/uploads/2017/07/best-drones-for-traffic-monitoring.jpeg>; (pristupljeno: srpanj 2017.)
- [17] URL:[http://www.israeli-weapons.com/weapons/aircraft/uav/aerostar/aerostar\\_p3.jpg](http://www.israeli-weapons.com/weapons/aircraft/uav/aerostar/aerostar_p3.jpg); (pristupljeno: srpanj, 2017.)
- [18] URL:<http://www.telegraph.co.uk/technology/news/11541504/Where-is-the-legal-line-in-flying-drones.html>; (pristupljeno: srpanj, 2017.)
- [19] URL:<http://www.danofficeit.com/Files/Billeder/uav-drone/application/Disaster%20Management.jpg>; (pristupljeno: srpanj, 2017.)
- [20] URL:<https://www.microdrones.com/en/mdaircraft/md4-1000/>; (pristupljeno: srpanj, 2017.)
- [21] URL:[http://www.photometrix.com.au/wp-content/uploads/2015/03/application\\_image\\_11.png](http://www.photometrix.com.au/wp-content/uploads/2015/03/application_image_11.png); (pristupljeno: srpanj, 2017)
- [22] URL:<http://narodne-novine.nn.hr/clanci/sluzbeni/dodatni/435818.pdf>, (pristupljeno: srpanj, 2017.)
- [23] V. Nikolić. Ispitivanje mogućnosti bespilotnih letjelica i pravna regulativa. Zagreb. Geodetski fakultet; 2015. Diplomski rad.
- [24] URL:[http://ardupilot.org/planner/\\_images/mission\\_planner\\_screen\\_flight\\_plan.jpg](http://ardupilot.org/planner/_images/mission_planner_screen_flight_plan.jpg); (pristupljeno: srpanj, 2017.)
- [25] URL:[https://www.adorama.com/images/cms/1692s2016-05-19\\_14-00-02.jpg](https://www.adorama.com/images/cms/1692s2016-05-19_14-00-02.jpg); (pristupljeno: rujan, 2017.)
- [26] Y. Du, C. Zhao, F. Li, Xu. Yang. An Open Data Platform for Traffic Parameters Measurement via Multirotor Unmanned Aerial Vehicles Video. Journal of advanced transportation. 2017.
- [27] L. Wang, F. Chen, H. Yin. Detecting and tracking vehicles in traffic by unmanned aerial vehicles. Columbian University. 2016.
- [28] G. Salvo, L. Caruso, A. Scordo. Urban Traffic analysis through an UAV. Palermo. University of Palermo. 2013.
- [29] B. Coifman, M. McCord, R. G. Mishalani, M. Iswalt, Yu. Ji. Roadway traffic monitoring from an unmanned aerial vehicle. SAD. The Ohio State University.

- [30] P. Cheng, G. Zhou, Z. Zheng. Detecting and counting vehicles from small low-cost UAV images. Kina. East China Institute of Technology 2015.
- [31] G. Tomić. Primjena bespilotnih letjelica u operacijama potrage i spašavanja. Zagreb. Fakultet prometnih znanosti. 2015. Diplomski rad.
- [32] F. Heintz, P. Rudol, P. Doherty. From images to traffic behavior – a UAV tracking and monitoring application. Linköping University. 2007.
- [33] G. Guido, V. Gallelli, D. Rogano, A. Vitale. Evaluating the accuracy of vehicle tracking data obtained from unmanned aerial vehicles. International Journal of Transportation Science and Technology. 2016.
- [34] G. Salvo, L. Caruso, A. Scordo, G. Guido, A. Vitale. Traffic data acquirement by unmanned aerial vehicle. European Journal of Remote Sensing. 2017.
- [35] URL:<https://www.researchgate.net/publication/236980566/figure/fig7/AS:398326966046720@1471979957267/Figure-7-LASE-and-LALE-UAS-on-display-at-2005-Naval-Unmanned-Aerial-Vehicle-Air-Demo.jpg> (pristupljeno: srpanj, 2017.)

## 9. Popis kratica

<b>ITS</b>	(Intelligent transport systems) inteligentni transportni sustavi
<b>UAV</b>	(Unmanned aerial vehicles) bespilotne letjelice
<b>GPS</b>	(Global positioning system) globalni pozicijski sustav
<b>VTOL</b>	(Vertical takeoff and landing) vertikalno polijetanje i slijetanje
<b>HACZ</b>	Hrvatska agencija za civilno zrakoplovstvo
<b>DGU</b>	Državna geodetski uprava
<b>EASA</b>	(European aviation safety agency) Europska agencija za zrakoplovnu sigurnost
<b>RPAS</b>	(Remotely piloted aircraft system) Daljinski upravljana letjelica
<b>PGDP</b>	Prosječni godišnji dnevni promet

## **10. Popis tablica**

Tablica 1. Kategorizacija letačkih operacija.....	16
Tablica 2. Razina usluge klasificirana rasponom gustoće (vozilo/km/traka) .....	49
Tablica 3. Rezultati istraživanja parametara prometnog toka dionice Zagrebačke ceste po metodama .....	49

## 11. Popis slika

Slika 1. Low altitude short i long endurance sustavi [36].....	4
Slika 2. Prikaz bespilotne letjelice prilikom nadzora prometa [16].....	5
Slika 3. Prijedlog dizajna zračnog prostora za male dronove od amazona [1].....	6
Slika 4. Video nadzor bespilotnom letjelicom [17].....	9
Slika 5. Britanski policijski dron [18] .....	10
Slika 6. Pregled područja pogođenog katastrofom [19] .....	11
Slika 7. Bespilotna letjelica za dostavu paketa [20] .....	13
Slika 8. Korištenje snimke za analizu prometnih tokova na raskrižju [21] .....	14
Slika 9. Pravila sigurnosti prilikom rukovanja bespilotnom letjelicom [23].....	18
Slika 10. Dijagram postupaka prema uredbi [23].....	21
Slika 11. Predložena metodologija [9] .....	25
Slika 12. Parametri projekta .....	26
Slika 13. Koraci za planiranje leta.....	27
Slika 14. Mission planner program [24].....	28
Slika 15. Kardanski prsten na bespilotnoj letjelici Phantom 4 [25].....	29
Slika 16. Koraci obrade podataka [9].....	30
Slika 17. Prikaz putanji vozila na raskrižju [9] .....	32
Slika 18. Snimka dijela prometnice sa bespilotne letjelice .....	33
Slika 19. Slika prije kalibriranja [26] .....	34
Slika 20. Slika nakon kalibriranja [26].....	35
Slika 21. Proces detekcije vozila [27] .....	35
Slika 22. Prikaz točnosti kod detektiranja i praćenja vozila [27].....	37
Slika 23. Korisničko sučelje programa Picomixer STA [10] .....	38
Slika 24. Dobiveni podaci o broju vozila po određenom smjeru kretanja [11].....	39
Slika 25. Dijagram prometnog opterećenja [11].....	40
Slika 26. Prikaz mjerenja brzina [11] .....	40
Slika 27. Primjer klasifikacije vozila [11].....	41
Slika 28. Prikaz područja emisija štetnih plinova [11] .....	42
Slika 29. Dionica glavne prometnice Zagrebačke ceste između dva križanja .....	44
Slika 30. Primjer određivanja udaljenosti između promatranih točaka na dionici ceste .....	45



Sveučilište u Zagrebu  
Fakultet prometnih znanosti  
10000 Zagreb  
Vukelićeva 4

## IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj \_\_\_\_\_ diplomski rad

isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu \_\_\_\_\_ diplomskog rada

pod naslovom **Primjena bespilotnih letjelica za analizu prometa u gradovima**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, \_\_\_\_\_ 18.9.2017 \_\_\_\_\_

Student/ica:

\_\_\_\_\_  
(potpis)